

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Igor Avbelj

**Sprotno posodabljanje priporočilnega
sistema za personalizacijo TV sporeda**

MAGISTRSKO DELO
ŠTUDIJSKI PROGRAM DRUGE STOPNJE
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: akad. prof. dr. Ivan Bratko

Ljubljana, 2015

Rezultati magistrskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljanje ali izkoriščanje rezultatov magistrskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

IZJAVA O AVTORSTVU MAGISTRSKEGA DELA

Spodaj podpisani Igor Avbelj, z vpisno številko **63090006**, sem avtor magistrskega dela z naslovom:

Sprotno posodabljanje priporočilnega sistema za personalizacijo TV sporeda

S svojim podpisom zagotavljam, da:

- sem magistrsko delo izdelal samostojno pod mentorstvom akad. prof. dr. Ivana Bratka,
- so elektronska oblika magistrskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko magistrskega dela,
- soglašam z javno objavo elektronske oblike magistrskega dela v zbirki "Dela FRI".

V Ljubljani, 20. januarja 2015

Podpis avtorja:

Zahvaljujem se mentorju in laboratoriju za umetno inteligenco.

Kazalo

1	Uvod	1
2	Podatki	5
2.1	Predpostavke	5
2.2	Vir podatkov	6
2.3	Predstavitev z atributi	6
2.4	Predstavitev podatkov	8
2.5	Branje podatkov	9
3	Pregled metod	11
3.1	Jaccardov indeks	11
3.2	Povprečje	11
3.3	Zgodovina	12
3.4	ECOCLE	12
3.5	kNN	17
3.6	BRISMF	20
3.7	Načini uporabe metod za priporočanje	21
3.8	Priporočanje dejanskih oddaj	23
4	Mere uspešnosti	25
4.1	Preciznost	25
4.2	Priklic	25
4.3	RMSE	26
5	Rezultati	27
5.1	Analiza podatkov	27

KAZALO

5.2	Primerjava okusa glede na dan v tednu	29
5.3	Rezultati evalvacije	30
6	Zaključek	47
A	Možne vrednosti atributov	53
A.1	Žanr	53
A.2	Leto izdelave	53
A.3	Jezik	54
B	Rezultati evalvacije	55
B.1	Rezultati evalvacije pri definiciji stvari A	55
B.2	Rezultati evalvacije pri definiciji stvari B	73
B.3	Rezultati evalvacije pri definiciji stvari C	90

Seznam uporabljenih kratic

kratica	angleško	slovensko
ECOCLE	Evolutionary co-clustering with ensembles	Evolucijsko hkratno razvrščanje v skupine z uporabo večih modelov
kNN	k Nearest Neighbours	Metoda k najbližjih sosedov
BRISMF	Biased Regularized Incremental Simultaneous Matrix Factorization	Pristranska regularizirana inkrementalna simultana matrična faktorizacija
RMSE	Root Mean Squared Error	Koren povprečne kvadratne napake

Povzetek

V tem magistrskem delu obravnavamo pripravo priporočilnega sistema za priporočanje TV oddaj. Imamo implicitno pridobljene podatke o ogledih TV oddaj. Priporočilni sistem bo temeljil na uporabi skupinskega izbiranja, saj to pomeni, da potrebujemo malo dodatnih informacij o oddajah. Področje TV oddaj se od ostalih področij, na katerih je uporaba priporočilnih sistemov že uveljavljena, razlikuje v tem, da se TV oddaje zelo redko ponavljajo. Ta problem omilimo z opisom oddaj z atributi. Priporočilni sistem bo priporočil množice atributov, ki jih s pomočjo TV sporeda preslikamo v TV oddaje. Za pripravo priporočilnega sistema smo preizkusili več različnih metod: zgodovino, BRISMF (*pristranska regularizirana inkrementalna simultana matrična faktorizacija*), kNN (*k najbližjih sosedov*), ECOCLE (*Evolucijsko hkratno razvrščanje v skupine z uporabo več modelov*). Ker metoda BRISMF ni inkrementalna, predlagamo izdelavo BRISMF modelov za vsak dan posebej, za izdelavo priporočil nato modele združimo. V primerjavi rezultatov različnih metod smo ugotovili, da daje naš predlagan način združevanja BRISMF modelov dobre rezultate v primerjavi z drugimi, že v osnovi inkrementalnimi metodami.

Abstract

Title: Real-time updating of a recommender for personalized TV program

In this master's thesis we prepare a recommender system for recommending TV programmes. The data documenting users' preferences was acquired implicitly. The recommender system will be based on collaborative filtering, because very little additional information about TV programmes is required. The main issue with recommending TV programmes is that they rarely repeat so we cannot use the types of recommenders commonly used in other domains. We deal with this problem by describing each TV programme with attributes and then recommending sets of attributes. These will be later converted to actual TV programmes using a programme guide. A recommender system for TV programmes must be able to include new data in real time and without retraining. We tested a few different methods for recommending TV programmes: history, BRISMF (*Biased Regularized Incremental Simultaneous Matrix Factorization*), kNN (*k Nearest Neighbours*) and ECOCLE (*Evolutionary Co-clustering with Ensembles*). Because BRISMF is not incremental, we propose building BRISMF models for every single day and then joining recommendations from these daily models. When compared to other methods, which are already incremental by design, our proposed method gives good results.

Poglavje 1

Uvod

V zadnjih letih smo priča vse bolj razširjeni uporabi priporočilnih sistemov. Porast se je začel predvsem s pojavom spletnih filmotek in spletnih trgovin. Uporabniki so čedalje bolj navajeni, da jim spletna trgovina še sama ponudi artikle v smislu: “Kupci, ki so kupili ta artikel, so kupili še: ...”. Tudi YouTubea¹ in podobnih strani si ne predstavljamo več ne da bi nam ob ogledu videa priporočale, kaj naj še pogledamo. Priporočilni sistemi pa se vse bolj širijo tudi na druga področja. Eno izmed teh je IP televizija. To področje prinaša s seboj tudi nekaj specifik, glavna težava, s katero se srečujemo je dejstvo, da se oddaje zelo redko ponavljajo.

Glavna prednost, ki jo IPTV ponuja (vir [10]) glede priporočil v primerjavi z ostalimi vrstami televizije, je možnost, da ponudnik zbira informacije o uporabniku. Ponudnik storitev točno ve, katero oddajo je uporabnik gledal in koliko časa jo je gledal. Na podlagi tega lahko ponudnik storitev ugotovi, katere oddaje bodo uporabniku všeč in mu jih tudi priporoča. Uporabniku za to ni potrebno eksplicitno oceniti oddaje, niti klikniti “Všeč mi je”. Slabost implicitno pridobljenih podatkov je manjša zanesljivost. Ponudnik lahko glede na uporabnikov okus pripravi tudi personaliziran TV spored, kjer uporabniku za celotni dan priporoči, kaj naj kdaj gleda. V tej magistrski nalogi se bomo ukvarjali predvsem s pripravo priporočilnega sistema, samo gradnjo personaliziranega TV sporeda pa bomo prepustili ponudniku storitev.

Glavna zelena lastnost priporočilnega sistema za TV oddaje je možnost spro-

¹<http://www.youtube.com>

tnega posodabljanja modelov (inkrementalni pristop). To pomeni, da lahko, ko dobimo nov podatek o gledanosti oddaje, model ustrezno posodobimo. Nikoli nam ni potrebno modela graditi znova v celoti. Vse metode, ki smo jih preizkusili, omogočajo takšen način učenja. Vse metode tudi temeljijo na tehniki, ki jo imenujemo *skupinsko izbiranje* (*collaborative filtering*). To pomeni, da nam za vsako stvar, ki jo želimo vključiti v sistem, ni potrebno poznati nobenih drugih podatkov, razen gledanosti uporabnikov. Ni nam potrebno poznati vsebine. Ker pa se TV oddaje zelo redko ponavljajo, smo se odločili za hibridni pristop, oddaje bomo opisali z atributi, slednje pa bomo priporočali. Ko bomo priporočili nekaj kombinacij atributov, bomo te z uporabo TV sporeda preslikali v dejanske oddaje.

Podatke, na katerih smo izvajali preizkuse, smo pridobili od enega izmed slovenskih ponudnikov IPTV. Delali smo na podatkih od 1.6.2013 do 30.6.2013. Podatki so bili pridobljeni implicitno. To ima za posledico ogromno količino podatkov. Podatki obsegajo približno 25 milijonov podatkov o ogledih oddaj na teden. Ker je to preveč za učinkovito testiranje, smo uporabili podatke samo nekaterih uporabnikov. Po začetni pripravi podatkov nam je ostalo 15 podatkov o gledanosti oddaje na uporabnika na dan, kar je še vedno več, kot bi jih bil uporabnik verjetno pripravljen eksplicitno podati. Za uporabnika vemo, koliko časa je gledal oddajo ter koliko časa je oddaja trajala. Naj omenimo še, da se pod enim uporabnikov v praksi skriva več ljudi, saj preko istega IPTV priključka televizijo običajno spremlja več ljudi. Tako se okus “uporabnika” spreminja zelo hitro. Precej manj informacij imamo o sami oddaji. Poznamo naslov, žanr, jezik, leto izdelave. Poleg tega imamo na voljo tudi TV spored.

Za pripravo priporočil smo uporabili različne metode: *povprečje*, *zgodovino*, *ECOCLE* (vir [4]), *kNN* (vir [3, 7]), *BRISMF* (vir [5, 8]). Metode smo uporabili v različnih načinih delovanja. Vse smo preizkusili v inkrementalnem načinu. Možnost inkrementalnega načina učenja je za področje IPTV ključna, saj vsak dan pridobimo veliko novih podatkov. Če bi morali vsakič na novo graditi model, bi za to potrebovali veliko preveč časa. Nekatere metode smo preizkusili tudi v drugih načinih: agregiranjem in okenskem. To smo naredili, da lahko primerjamo rezultate pridobljene na ta dva načina z rezultati, pridobljenimi z uporabo inkrementalnega načina. Ugotovili smo, da najboljše rezultate dajejo metode, ki temeljijo na zgodovini. Od ostalih metod se kot dobro izkaže metoda združevanja dnevnih modelov

BRISMF, ki smo jo zasnovali sami in je tudi glavni doprinos tega dela. Ugotovili smo tudi, da je v podatkih veliko šuma, kar je, glede na implicitno pridobljene podatke pričakovano. Prav tako smo ugotovili, da se okus uporabnikov ob koncu tedna razlikuje od okusa uporabnikov med tednom.

Za evalviranje metod smo izbrali tri mere: RMSE (*vir [8]*), preciznost (*vir [3]*) in priklic (*vir [3]*). Ugotovili smo, da je potrebno pravilno izbrati mere za evalvacijo priporočilnega sistema. Mera, ki je na področju priporočilnih sistemov zelo razširjena, je RMSE. Za dejanskega uporabnika sta pomembnejši meri preciznost in priklic. Osredotočili smo se predvsem na rezultate na nivoju napovedanih kombinacij vrednosti atributov. Te smo kasneje preslikali v dejanske oddaje s pomočjo sporeda. To je težavno, saj je vsak dan na sporedu veliko oddaj.

Pri pregledu sorodnega dela smo ugotovili, da je člankov na temo priporočilnih sistemov za IPTV malo. V člankih [6] se ukvarjajo z priporočanjem TV oddaj. Predlagajo nekaj enostavnejših algoritmov in se ukvarjajo s tehničnim delom prikaza priporočil na TV sprejemnikih. Predlagajo uporabo drugega zaslona (npr. tablice) za priporočanje, personalizacijo TV sporeda in prikaz oddaj, ki bi bile uporabniku všeč. Mi smo se bolj osredotočili na same metode za izdelavo priporočil. Članek [13] je pregled področja IPTV priporočilnih sistemov. Predlagajo logični model sistema. V članku [1] predlagajo hkratno razvrščanje v skupine. V članku [4] uporabijo hkratno razvrščanje v skupine in ga nadgradijo z evolucijsko optimizacijo in uporabo več modelov tudi v inkrementalni fazi. V knjigi [3] je celoten pregled področja priporočilnih sistemov. Med drugim je opisan tudi *kNN* pristop. V člankih [12, 17] je podrobnejši pregled področja *skupinskega izbiranja*. V članku [7] je razloženo, kako lahko *kNN* pristop realiziramo inkrementalno. V članku [8] je opisana metoda *BRISMF*. V članku [5] je razloženo, kako lahko pri metodi *BRISMF* upoštevamo vpliv časa. V članku [16] je predstavljenih nekaj mer, ki se uporabljajo za merjenje uspešnosti priporočilnih sistemov. V članku [9] se ukvarjajo z uporabo podatkov s socialnih omrežij, s katerimi si pomagajo pri izdelavi priporočil za TV oddaje. Za to se nismo odločili, saj pri podatkih, ki jih imamo, uporabnikov ne moremo povezati z njihovimi profili na socialnih omrežjih. Naši podatki so anonimizirani. V članku [14] pripravijo priporočilni sistem, ki uporablja implicitno in eksplicitno pridobljene podatke. V članku [15] uporabijo skupinsko filtriranje in priporočilo temelječe na vsebini. V članku [11] povdarjajo

pomembnost pristopa *k najbližjih sosedov* s strani stvari in ne s strani uporabnikov, predvsem z vidika skalabilnosti sistema. Pri pregledu sorodnega dela nismo našli nobenih primerljivih eksperimentalnih rezultatov.

Želimo torej pripraviti priporočilni sistem, pri katerem bo možno hitro upoštevati nove podatke. Sistem mora uporabniku priporočiti oddaje, ki mu bodo všeč. Z uporabo takšnega priporočilnega sistema bo lahko ponudnik storitev IPTV uporabniku pripravil personaliziran TV spored, ki bo uporabniku olajšal iskanje oddaje, ki mu bo všeč.

V poglavju 2 predstavimo, kako in kdaj so bili podatki pridobljeni, kako jih pred uporabo obdelamo in kako smo oddaje opisali z atributi. V poglavju 3 opišemo metode, ki smo jih uporabili, ter predlagamo metodo *dnevni BRISMF*. Predstavimo tudi metode za evalvacijo priporočilnih sistemov. V poglavju 5 predstavimo ugotovitve. Najprej sledi nekaj statistične obdelave podatkov. Nato predstavimo ugotovitve o okusu uporabnikov. Za tem sledijo še rezultati evalvacije različnih metod.

Poglavje 2

Podatki

Specifika te magistrske naloge je, da se ukvarjamo s priporočanjem TV oddaj. Večinoma se na področju skupinskega izbiranja uporabljajo eksplicitni podatki o stvareh, ki se pogosto ponavljajo. Tipični primer je ocenjevanje in priporočanje filmov. Prednost priporočilnih sistemov temelječih na skupinskem izbiranju je v tem, da nam ni potrebno poznati stvari, ki jih priporočamo. Ker pa se TV oddaje ponavljajo zelo redko, smo se odločili, da bomo TV oddaje opisali z atributi. Priporočali bomo kombinacije vrednosti atributov, za katere menimo, da bodo uporabniku všeč. Tako moramo vseeno poznati nekaj podatkov o oddaji, še vedno pa nam ni potrebno poznati vsebine le-te.

Delamo na podatkih, ki so bili zajeti implicitno. To pomeni, da ni uporabnika nihče vprašal, kako všeč mu je bila oddaja. Všečnost oddaje smo ugotovili iz opazovanja uporabnikovih akcij. To pomeni, da je podatke enostavno pridobivati. Podatkov o ogledih oddaj je zelo veliko, vendar so ti manj zanesljivi kot bi bili, če bi bili pridobljeni eksplicitno. Prav tako tudi ne vemo kdo je oddajo gledal, saj isti TV sprejemnik ponavadi uporablja več ljudi, vsak od njih pa ima svoj okus.

2.1 Predpostavke

Pri začetni obdelavi podatkov smo naredili nekaj predpostavk. Nekatere podatke o ogledih smo odstranili, saj menimo, da niso merodajni.

Odstranili smo vse oddaje, ki so krajše od 15 minut. Tu gre za kratke oddaje, ki so po navadi na sporedu med oglasi. Te oddaje so prekratke, da bi jih bilo

smiselno priporočiti uporabniku. Odstranili smo tudi vse podatke o ogledih, ki so bili krajši od 5 minut. Prav tako smo odstranili vse podatke, kjer uporabnik v zadnjih 2 urah ni naredil nobene akcije (npr. sprememba glasnosti, ...). Velika verjetnost je, da ima uporabnik le prižgan TV sprejemnik, oddaje pa ne gleda aktivno in zato tudi podatek o gledanosti oddaje ni merodajen. Iz podatkov smo odstranili tudi vse oddaje z erotično vsebino.

Da smo zmanjšali količino podatkov, smo vzeli samo podatke 1000 uporabnikov z največ ogledi.

2.2 Vir podatkov

Podatki so bili zbrani s strani enega izmed slovenskih ponudnikov IP televizije. Zajeti so bili v obdobju med 1.6.2013 in 30.6.2013. Podatki so bili pridobljeni implicitno. Ko uporabnik na svojem IP TV sprejemniku naredi neko akcijo (npr. zamenja TV program), se podatki o tej akciji pošljejo ponudniku storitev. Slednji je nato podatke anonimiziral in obdelal. Poleg teh podatkov imamo na voljo tudi TV spored. Tako lahko za vsak trenutek ugotovimo, katero oddajo je uporabnik gledal.

Vseh podatkov o ogledih oddaj je 131.473.076. Po tem, ko smo iz podatkov odstranili vse ogledne oddaje, ki po naših predpostavkah niso merodajni (glej 2.1), je bilo podatkov 438.626. V povprečju imamo za vsakega uporabnika za vsak dan podatek o gledanosti 15 oddaj. To je verjetno veliko več, kot bi jih bil uporabnik pripravljen eksplicitno podati.

2.3 Predstavitev z atributi

Ker se oddaje zelo redko ponavljajo, smo vse produkte opisali z različnimi atributi. S priporočilnim sistemom smo nato priporočali kombinacijo vrednosti atributov. Glede na TV spored za želeni dan sistem nato uporabniku naredi priporočila. Vsako kombinacijo vrednosti atributov bomo imenovali stvar (*item*), saj imamo na področju skupinskega izbiranja ponavadi opraviti z uporabniki in s stvarmi.

Preizkusili smo tri različne definicije stvari:

- Definicija stvari A: stvar = [žanr]

- Definicija stvari B: stvar = [žanr, leto izdelave, jezik, časovni opis z vikendom]
- Definicija stvari C: stvar = [žanr, leto izdelave, jezik, časovni opis brez vikenda]

Za uporabo prve definicije stvari smo se odločili, ker je zelo enostavna, obenem pa pove veliko o sami oddaji. Prav tako je podatke o žanru oddaje skoraj vedno mogoče pridobiti. Kompleksnejšo definicijo stvari smo razdelili na dve, pri čemer ena upošteva posebej oddaje, ki so na sporedu ob koncu tedna. To smo naredili, ko smo ugotovili, da se okus gledalcev med tednom in ob koncu tedna razlikuje (glej razdelek 5.2).

V naslednjih razdelkih so opisani posamezni atributi.

2.3.1 Žanr

Žanr nam pove veliko o vsebini oddaje. Možnih vrednosti je 86. Najpogostejši žanri so: *documentary*, *tv-show*, *entertainment-show*, *music-show*, *cartoon*. Vse možne vrednosti so našteje v dodatku A.1.

2.3.2 Leto izdelave

Leto izdelave oddaje smo vključili predvsem zato, ker se pristopi pri kreiranju oddaj s časom spreminjajo. Nekateri uporabniki raje gledajo stare oddaje, drugi pa imajo raje modernejše. Leto izdelave smo zaokrožili na 10. Tako smo zmanjšali število različnih vrednosti, obenem pa podatkov nismo preveč posplošili. Vse možne vrednosti atributa so našteje v A.2.

2.3.3 Jezik

Uporabniki razumejo omejeno število jezikov. Kljub temu, da med podatki prevladuje le nekaj (angleščina, slovenščina, hrvaščina) različnih jezikov, se nam zdi, da je jezik pomemben atribut, še posebej za skupine gledalcev, ki ne razumejo tujih jezikov. Vsi jeziki so našteji v dodatku A.3.

Prav tako nam jezik pove veliko o okusu gledalca. Zaradi različnih kulturnih okolij, v katerih se jezik uporablja, se oddaje v nekaterih jezikih kljub istemu žanru zelo razlikujejo od drugih.

2.3.4 Časovni opis

Gre za atribut, ki nam pove, kdaj je bila oddaja na sporedu. To z vidika same oddaje ni tako pomembno, pomembno pa je z vidika uporabnika. Pogosto se namreč dogaja, da preko istega TV sprejemnika gledajo oddaje različni uporabniki, vendar pa ne hkrati. S pomočjo časa, ko je bila oddaja na sporedu lahko upoštevamo, da imajo različni uporabniki različen okus. Tako lahko npr. zjutraj priporočamo risanke, zvečer pa kriminalke.

Časovni opis definiramo s pomočjo tabele 2.1. V kolikor želimo posebej obrav-

Tabela 2.1: Časovni opis

ura začetka oddaje	vrednost atributa	vrednost atributa ob koncu tedna
0 do 5	1	11
5 do 11	2	12
11 do 15	3	13
15 do 20	4	14
20 do 24	5	15

navati vikende in dni med tednom (definicija stvari B), tedaj oddajam, ki se začnejo med vikendom pri vrednosti atributa prištejemo 10 (zadnji stolpec tabele). Če želimo uporabiti definicijo stvari C, tedaj tudi ob koncih tedna vrednosti atributa nastavimo enako kot med tednom.

2.4 Predstavitev podatkov

Podatke imamo predstavljene z redko preferenčno matriko R . Matrika vsebuje podatke o relativni gledanosti oddaj. Predpostavili smo, da je oddaja uporabniku všeč, če jo je gledal vsaj 20 minut. Gledanost smo izračunali po enačbi 2.1.

$$r = \frac{\min(\text{dolžina gledanja oddaje, 20 minut})}{\min(\text{dolžina oddaje, 20 minut})} \quad (2.1)$$

Vrstica v matriki R predstavlja profil uporabnika. Stolpec predstavlja profil stvari (ang. *item*). \bar{R} je globalna povprečna gledanost. R_{ui} je gledanost uporabnika u stvari i . Množica τ je množica vektorjev (u, i, r) , kjer je u uporabnik, i stvar in r gledanost. Množica vsebuje tiste vektorje, ki so v učni množici. Velja torej $(u, i, r) \in \tau \Leftrightarrow R_{ui} \neq \mathbf{NULL}$.

Definiramo množico R_u , ki je množica vseh stvari, ki jih je gledal uporabnik u . Podobno naj bo množica R_i množica vseh uporabnikov, ki so gledali stvar i . Naj bo \bar{R}_u uporabnikova povprečna gledanost. Naj bo \bar{R}_i povprečna gledanost stvari i . U je množica vseh uporabnikov, I pa je množica vseh stvari.

Pri evalvaciji različnih metod smo predpostavili da je uporabniku stvar (in tudi oddaja) všeč, če je njegova gledanost te stvari večja od njegove povprečne gledanosti za dan, na katerem smo izvajali evalvacijo.

2.5 Branje podatkov

Ker priporočilni sistem priporoča stvar (*item*) in ne direktno TV oddaje, moramo še nekaj pozornosti nameniti branju podatkov o oddajah in preslikavi slednjih v stvari.

Za vsak dan imamo na voljo podatke za vsakega uporabnika. Vemo, katere oddaje je gledal in kakšno gledanost je dosegel pri kateri oddaji. Ko beremo podatke za trenutni dan, vedno preberemo podatke za enega uporabnika naenkrat. Za vsako oddajo poznamo vse potrebne vrednosti atributov in jo tako lahko preslikamo v stvar. Kadar se več oddaj preslika v isto stvar, vzamemo kot gledanost stvari maksimalno gledanost vseh oddaj, ki se preslikajo v to stvar. Priporočilnemu sistemu nato podamo podatke, v obliki `[uporabnik, stvar, gledanost]` za vsako stvar, v katero se preslika vsaj ena oddaja.

Če se več oddaj preslika v isto stvar, kot smo že omenili, vzamemo kot gledanost stvari maksimalno gledanost teh oddaj. Razlog za to je preprost. Uporabnik je morda eno izmed oddaj že gledal in je zato večjo gledanost namenil drugi oddaji. To pa ne pomeni, da mu *stvar* ni všeč. Lahko se tudi zgodi, da sta istočasno na

sporedu dve oddaji, ki se obe preslikata v stvar i in je uporabnik iz očitnih razlogov gledal le eno izmed njiju, kar pa ne pomeni, da mu je stvar i manj všeč.

Poglavje 3

Pregled metod

3.1 Jaccardov indeks

Jaccardov index (glej vir [3]) uporabimo za primerjavo množic stvari, ki so uporabnikom všeč po posameznih dneh. S tem primerjamo okus uporabnikov med tednom in ob koncu tedna.

Za vsakega uporabnika za vsak par dni X, Y po enačbi 3.1 izračunamo podobnost množic. Nato za vsak par dni te podobnosti povprečimo preko vseh uporabnikov.

$$J(X, Y) = \frac{|X \cap Y|}{|X \cup Y|} \quad (3.1)$$

3.2 Povprečje

Povprečje je najenostavnejša metoda za priporočanje, ki smo jo uporabili. Služi kot osnova za primerjavo z drugimi metodami. Napoved za uporabnika u in stvar i izračunamo po enačbi 3.2. V kolikor gre za novega uporabnika, metoda vrne povprečje podatkov o ogledih stvari. Če gre za novo stvar, metoda vrne povprečje podatkov o ogledih, ki jih je naredil uporabnik. Če nas zanima napoved gledanosti za uporabnika in stvar, ki ju model še ne pozna, tedaj vrne globalno gledanost \bar{R} .

Ob primerni implementaciji lahko model inkrementalno posodabljam. Za vsakega uporabnika imamo shranjeno vsoto gledanosti vseh stvari in števec stvari,

ki so vključene v vsoti. Podobno za vsako stvar. S pomočjo preferenčne matrike lahko nato vsote in števce ustrezno popravljamo. Na tak način shranjujemo razne povprečne vrednosti pri vseh metodah.

$$\hat{R}_{ui} = \begin{cases} \frac{\overline{R_u} + \overline{R_i}}{2} & ; u \in U \wedge i \in I \\ \overline{R_u} & ; u \in U \wedge i \notin I \\ \overline{R_i} & ; u \notin U \wedge i \in I \\ \overline{R} & ; u \notin U \wedge i \notin I \end{cases} \quad (3.2)$$

3.3 Zgodovina

Tudi metoda zgodovine je enostavna. Gre za inkrementalno metodo. Ko dobimo nov podatek (u, i, r) si tega shranimo, posodobimo pa tudi povprečje uporabnika u in povprečje stvari i .

Ko delamo napoved, najprej pogledamo v preferenčno matriko R . Če imamo za zahtevano kombinacijo uporabnika u in stvari i vrednost R_{ui} jo vrnemo, sicer napoved naredimo z metodo povprečja (glej razdelek 3.2).

Ena izmed izpeljank, ki smo jih uporabili je tudi ta, da za podatke v R uporabimo okno. Podatke, ki so prestari lahko iz matrike R brišemo. Okno je lahko fiksne ali spremenljive dolžine. Uporabljamo lahko podatke zadnjih n dni, ali pa npr. podatke od zadnje nedelje.

3.4 ECOCLE

Kratika *ECOCLE* pomeni *Evolutionary co-clustering with ensembles* oziroma evolucijsko hkratno razvrščanje v skupine, z uporabo večih modelov. Uporabnike in stvari razdelimo na skupine, nakar preferenčno matriko uporabnikov in stvari zmanjšamo in posplošimo na preferenčno matriko skupin uporabnikov in skupin stvari. Par (*skupina uporabnika*, *skupina stvari*) imenujemo ko-skupina.

Opis metode je povzet po viru [4]. Uporabnike in stvari najprej naključno razdelimo v skupine. Nato to razdelitev lokalno optimiziramo (glej razdelek 3.4.2). Takih modelov naredimo več, nakar jih z evolucijsko metodo izboljšamo (glej razdelek 3.4.3). Ker pri začetnem učenju uporabimo evolucijsko optimizacijo, je začetno učenje počasnejše, a so tako dobljeni modeli boljši in tudi po inkrementalnim

učenju dajejo boljše rezultate. Ohranimo vse modele, ki predstavljajo zadnjo iteracijo evolucije. Te modele nato uporabljamo za generiranje napovedi, hkrati pa jih tudi inkrementalno (sprotno) posodabljam. Inkrementalno posodabljanje pomeni, da sta fazi učenja in napovedovanja združeni in da, ko dobimo nov podatek ni potrebno modela graditi na novo.

Pri napovedovanju gledanosti smo, tako kot v članku [4] uporabili rezidualne. Model predikcije je predstavljen z enačbo 3.3.

$$\hat{R}_{ui} = \overline{R_u} + \overline{R_i} - \overline{R} + \epsilon_{ui} \quad (3.3)$$

Za $\forall(u, i, r) \in \tau$ je torej rezidual ϵ_{ui} definiran z enačbo 3.4.

$$\epsilon_{ui} = R_{ui} - (\overline{R_u} + \overline{R_i} - \overline{R}) \quad (3.4)$$

Imamo k skupin uporabnikov in l skupin stvari. Funkciji ρ in γ slikata uporabnike in stvari v ustrezne skupine (enačbi 3.5 in 3.6). Naj omenimo, da $u \in U$ ni zadostni pogoj, da je ρ definirana za u . Podobno velja tudi pri stvareh. Bolj podroben opis tega se nahaja v razdelku 3.4.4.

$$\rho : u \in \mathcal{D}(\rho) \rightarrow \{1, \dots, k\} \quad (3.5)$$

$$\gamma : i \in \mathcal{D}(\gamma) \rightarrow \{1, \dots, l\} \quad (3.6)$$

Z razdelitvijo uporabnikov in stvari v ko-skupine bomo dosegli generalizacijo (posplošitev) in hkrati zmanjšanje preferenčne matrike (primer na enačbi 3.7). Namesto velike in redke preferenčne matrike bomo uporabljali manjšo polno matriko rezidualov. Matrika rezidualov ϵ_{mn} nima nedefiniranih vrednosti. Če se med delovanjem zgodi, da v katero ko-skupino ne spada noben uporabnik in stvar, v to polje zapišemo vrednost 0. Priporočilo bo tedaj torej sestavljeno le iz povprečja uporabnika, povprečja stvari in globalnega povprečja.

$$R_{ui} = \begin{matrix} & i_1 & i_2 & i_3 & i_4 & i_5 & \dots \\ \begin{matrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ \vdots \end{matrix} & \begin{bmatrix} & 0.4 & 0.2 & & & \dots \\ 0.1 & 0.3 & & & 0.2 & \dots \\ & & & 0.5 & 0.9 & \dots \\ 0.1 & & & 0.5 & 0.1 & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots \end{bmatrix} \end{matrix} \rightarrow \epsilon_{mn} = \begin{matrix} & 1 & 2 & \dots & l \\ \begin{matrix} 1 \\ 2 \\ \vdots \\ k \end{matrix} & \begin{bmatrix} 0.3 & 0.3 & \dots & 0.1 \\ 0.7 & 0.6 & \dots & 0.2 \\ \vdots & \vdots & \ddots & \vdots \\ 0.1 & 0.4 & \dots & 0.8 \end{bmatrix} \end{matrix} \quad (3.7)$$

Če sta uporabnik u in stvar i že uvrščena v skupino, napoved izdelamo po enačbi 3.8. P je množica vseh modelov, ki jih uporabljamo. $\rho^{(p)}(u)$ je skupina, v katero v modelu p spada uporabnik u . $\gamma^{(p)}(i)$ je skupina, v katero v modelu p spada stvar i . $Z_{u\gamma^{(p)}(i)}^{(p)}$ je povprečna napaka napovedi za uporabnika u , skupino v katero spada stvar i v modelu p . $Z_{i\rho^{(p)}(u)}^{(p)}$ je povprečna napaka napovedi za stvar i in skupino v katero spada uporabnik u v modelu p . $\epsilon_{\rho^{(p)}(u)\gamma^{(p)}(i)}^{(p)}$ je rezidual skupine uporabnikov, v katero spada uporabnik u , in skupine stvari, v katero spada stvar i . Vsak model p ima svoje rezidualne, svojo razdelitev v skupine ter svoje povprečne napake Z .

$$\hat{R}_{ui} = \overline{R}_u + \overline{R}_i - \overline{R} + \frac{\sum_{p \in P} e^{-Z_{u\gamma^{(p)}(i)}^{(p)} - Z_{i\rho^{(p)}(u)}^{(p)}} \cdot \epsilon_{\rho^{(p)}(u)\gamma^{(p)}(i)}^{(p)}}{\sum_{p \in P} e^{-Z_{u\gamma^{(p)}(i)}^{(p)} - Z_{i\rho^{(p)}(u)}^{(p)}}} \quad (3.8)$$

Če uporabnik u in stvar i še nista uvrščena v skupine, izdelamo napoved s pomočjo enačbe 3.9. n_u je število podatkov o uporabniku u . n_i je število podatkov o stvari i . ω je prag, ki ga v članku [4] nastavijo na vrednost 3. Ta prag je pomemben zato, ker podatki o uporabniku (ali stvari), o katerem še nimamo veliko podatkov, niso dovolj relevantni, in je bolje izdelati bolj splošno napoved. Ta parameter se uporablja tudi pri inkrementalnem učenju (glej razdelek 3.4.4), kot prag za vključitev uporabnika ali stvari v skupino.

$$\hat{R}_{ui} = (1 - S_{n_u, \omega} - S_{n_i, \omega})\overline{R} + S_{n_u, \omega}\overline{R}_u + S_{n_i, \omega}\overline{R}_i \quad (3.9)$$

$$S_{r, \omega} = \begin{cases} \frac{r}{\omega} & ; r < \omega \\ 1 & ; \text{sicer} \end{cases} \quad (3.10)$$

3.4.1 Začetno učenje

Izberemo si velikost populacije za evolucijsko optimizacijo. Izberemo število skupin uporabnikov in stvari. Vsakemu osebk začetne populacije (modelu) nastavimo naključno razporeditev uporabnikov in stvari v skupine (funkciji ρ in γ). Vsak osebek optimiziramo z Bregmanovo optimizacijo (glej 3.4.2). Nato pričnemo z evolucijsko optimizacijo (glej 3.4.3). Potem vsem modelom, ki jih ohranimo, to so osebk zadnje populacije, nastavimo povprečne napake Z . To naredimo tako, da gremo preko vseh podatkov, na katerih smo izvajali začetno učenje in za vsak podatek

izdelamo še napoved. Iz teh podatkov nato izračunamo povprečne napake. Za vsakega uporabnika shranimo povprečno napako za vsako skupino stvari. Podobno tudi za vsako stvar shranimo povprečno napako za vsako skupino uporabnikov. Te podatke nato uporabljamo pri izdelavi napovedi po enačbi 3.8.

3.4.2 Bregmanova optimizacija

Z Bregmanovo optimizacijo lokalno optimiziramo razporeditev uporabnikov in stvari v skupine. Opis metode je povzet po viru [1], a je prilagojen za našo predstavitev podatkov, v članku [1] namreč uporabljajo drugačno enačbo za izdelavo priporočil (brez rezidualov). Konvergenco lahko ugotovimo tako, da štejemo število uporabnikov in stvari, ki so zamenjali skupino. Ko je slednje dovolj majhno, prenehamo z optimizacijo.

Algoritem 1: Bregmanova optimizacija

Vhod: Razporeditev v skupine ρ in γ , podatki R_{ui} , množici uporabnikov U in stvari I , št. skupin uporabnikov k in št. skupin stvari l

Rezultat: Lokalno optimizirana razporeditev v skupine (ρ, γ)

izračunaj $\overline{R_u}$ in $\overline{R_i}$;

dokler ne konvergira ponavlja

izračunaj povprečni rezidual v vseh ko-skupinah ϵ_{mn} ;

za $\forall u \in U$ **ponavlja**

$$\left[\rho(u) = \arg \min_{1 \leq g \leq k} \sum_{i \in R_u} (R_{ui} - (\overline{R_u} + \overline{R_i} - \overline{R} + \epsilon_{g, \gamma(i)}))^2; \right.$$

za $\forall i \in I$ **ponavlja**

$$\left[\gamma(i) = \arg \min_{1 \leq g \leq l} \sum_{u \in R_i} (R_{ui} - (\overline{R_u} + \overline{R_i} - \overline{R} + \epsilon_{\rho(u), g}))^2; \right.$$

3.4.3 Evolucijska optimizacija

Evolucijsko optimizacijo uporabimo pri začetnem učenju modelov. Začetno učenje je zato sicer precej počasnejše, a so tako dobljeni modeli boljši.

V vsaki iteraciji evolucije izberemo 2 modela, p_1 in p_2 , ki ju bomo križali. Izberemo novo število skupin uporabnikov ter stvari. To število je povprečje iz obeh izbranih modelov ter neka naključna sprememba. Maksimalne vrednosti

naključnih sprememb podamo kot parameter. Novo število skupin uporabnikov naj bo k , novo število skupin stvari pa imenujmo l .

Nato iz obeh modelov izračunamo nove delitve uporabnikov in stvari v skupine. To naredimo tako, da poiščemo največje preseke med vsemi pari skupin uporabnikov. Največjih $k - 1$ presekov naj predstavlja prvih $k - 1$ novih skupin uporabnikov. V novo k -to skupino uporabnikov pa uvrstimo vse preostale uporabnike. Enak postopek nato ponovimo še za skupine stvari. Nato novo razdelitev lokalno optimiziramo z Bregmanovo optimizacijo (razdelek 3.4.2). Tako smo dobili nov model p_n , ki ga dodamo med osebkke.

Napako modela lahko izračunamo po enačbi 3.11. ω_{ui} je 1, če imamo podatek za uporabnika u in stvar i , sicer pa ima vrednost 0.

$$e^{(p)} = \sum_u \sum_i \omega_{ui} \left(\epsilon_{ui} - \epsilon_{\rho^{(p)}(u)\gamma^{(p)}(i)}^{(p)} \right) \quad (3.11)$$

Najslabši model zavržemo in tako ohranimo fiksno velikost populacije.

3.4.4 Inkrementalno posodabljanje

Ko dobimo nov podatek o uporabniku u in stvari i , za vsak model najprej pogledamo, če sta uporabnik in stvar uvrščena v ustrezni skupini. Če sta, samo ustrezno posodobimo povprečni rezidual $\epsilon_{\rho(u)\gamma(i)}$, povprečje uporabnika in povprečje stvari. Vedno, ne glede na uvrstitev uporabnika in stvari v skupini, si nov podatek zapomnimo. Vsak model $p \in P$ posodobimo posebej.

Sicer imamo več scenarijev. Lahko imamo uporabnika u , ki ga še nimamo uvrščenega v skupino in stvar i , ki je že uvrščena, ali obratno. Recimo, da smo dobili podatek, ki se nanaša na uporabnika, ki ga še nimamo uvrščenega v skupino in stvar, ki jo že imamo uvrščeno.

Najprej pogledamo, koliko podatkov o uporabniku že imamo. Če jih imamo več kot ω (vključno z novim podatkom), potem ga po enačbi 3.12 uvrstimo v ustrezno skupino. $n_{u,h}$ je število podatkov, ki jih ima uporabnik u v skupini stvari h . ϵ'_{gh} predstavlja rezidual, ki bi ga imela ko-skupina v primeru, da bi novega uporabnika uvrstili v skupino uporabnikov g . Tako bo kvadratna napaka najmanjša, za vse možne skupine uporabnikov.

$$\rho(u) = \arg \min_{1 \leq g \leq k} \sum_{1 \leq h \leq l} n_{u,h} (\epsilon'_{gh} - \epsilon_{gh})^2 \quad (3.12)$$

Nato posodobimo vse potrebne rezidualne ko-skupin. Spremenijo se tisti, ki pripadajo skupini uporabnika in skupinam vseh stvari, za katere imamo za danega uporabnika podatek in so že uvrščene v skupino.

V primeru da niti uporabnika niti stvari še nimamo uvrščenih v skupino, si novi podatek samo shranimo in skupin ne spreminjamo, saj niti za uporabnika, niti za stvar nimamo vsaj ω podatkov.

S posodobljenim modelom izdelamo napoved za uporabnika u in stvar i . S pomočjo danega novega podatka o gledanosti in te napovedi izračunamo napako napovedi. Če imamo uporabnika u uvrščenega v skupino, posodobimo povprečno napako $Z_{i\rho(u)}$. Če imamo stvar i uvrščeno v skupino, posodobimo povprečno napako $Z_{u\gamma(i)}$.

3.5 kNN

Kratica *kNN* pomeni *k Nearest Neighbours* oziroma *k najbližjih sosedov*. Model temelji na predpostavki, da so podobnim uporabnikom vseh podobne stvari (vir [3]). Za računanje podobnosti med uporabniki smo uporabili Pearsonov korelacijski koeficient, ker se ga da izračunati iz podatkov, ki se jih da inkrementalno posodabljati. Metoda je povzeta po članku [7].

Za poenostavitev definirajmo enačbo 3.13. CI_{u_1, u_2} je torej množica vseh stvari, ki sta jih gledala uporabnika u_1 in u_2 .

$$CI_{u_1, u_2} = R_{u_1} \cap R_{u_2} \quad (3.13)$$

Podobnost med uporabnikoma u_1 in u_2 je definirana z enačbo 3.14.

$$S(u_1, u_2) = \frac{\sum_{i \in CI_{u_1, u_2}} (R_{u_1, i} - \overline{R_{u_1}}) (R_{u_2, i} - \overline{R_{u_2}})}{\sqrt{\sum_{i \in CI_{u_1, u_2}} (R_{u_1, i} - \overline{R_{u_1}})^2} \cdot \sqrt{\sum_{i \in CI_{u_1, u_2}} (R_{u_2, i} - \overline{R_{u_2}})^2}} = \frac{B}{\sqrt{C} \cdot \sqrt{D}} \quad (3.14)$$

Za vsak par uporabnikov (u_1, u_2) imamo shranjene vrednosti B , C in D . Na voljo imamo tudi preferenčno matriko. Poleg tega imamo za vsakega uporabnika

u shranjeno še njegovo povprečno gledanost R_u . Tako lahko podobnosti med uporabniki inkrementalno posodabljam. Za začetno učenje izračunamo vrednosti B , C in D direktno po enačbi 3.14. Ko model posodabljam inkrementalno, za vsak nov podatek posodobimo samo potrebne vrednosti B , C , D .

Recimo, da smo med inkrementalnim posodabljanjem dobili nov podatek (u_j, i_k, R_{u_j, i_k}) . Za uporabnika u_j moramo posodobiti vrednosti B , C , D za $\{\forall u \in U; u \neq u_j\}$. B' , C' in D' so nove vrednosti. Če je uporabnik u_j že imel podatek o gledanosti stvari i_k , bomo nov podatek o gledanosti označili z u'_{u_j, i_k} . Množica $CI = CI_{u_1, u_2}$ vsebuje stvari, ki so bile uporabnikoma skupne, pred dodajanjem novega podatka. Po posodobitvi B , C in D posodobimo tudi povprečje uporabnika $\overline{R_{u_j}}$ in podatek zapišemo v preferenčno matriko.

3.5.1 Inkrementalno posodabljanje B

Če uporabnik u nima podatka o gledanosti stvari i_k , potem B posodobimo po enačbi 3.15.

$$B' = B + (\overline{R_{u_j}}' - \overline{R_{u_j}}) \cdot \left(|CI| \cdot \overline{R_u} - \sum_{i \in CI} R_{u, i} \right) \quad (3.15)$$

Če uporabnik u podatek o gledanosti stvari i_k ima, uporabnik u_j pa podatka o gledanosti te stvari do sedaj še ni imel, tedaj B posodobimo po enačbi 3.16.

$$B' = B + (\overline{R_{u_j}}' - \overline{R_{u_j}}) \cdot \left(|CI| \cdot \overline{R_u} - \sum_{i \in CI} R_{u, i} \right) + (R_{u_j, i_k} - \overline{R_{u_j}}') (R_{u_j, i_k} - \overline{R_u}) \quad (3.16)$$

Če sta uporabnika u in u_j podatek o gledanosti stvari i_k že imela, potem B posodobimo po enačbi 3.17.

$$B' = B + (\overline{R_{u_j}}' - \overline{R_{u_j}}) \cdot \left(|CI| \cdot \overline{R_u} - \sum_{i \in CI} R_{u, i} \right) + (R_{u, i_k} - \overline{R_u}) (R'_{u_j, i_k} - R_{u_j, i_k}) \quad (3.17)$$

3.5.2 Inkrementalno posodabljanje C

Če uporabnik u nima podatka o gledanosti stvari i_k , potem C posodobimo po enačbi 3.18.

$$C' = C + 2 \cdot \sum_{i \in CI} R_{u_j, i} \left(\overline{R_{u_j}} - \overline{R_{u_j}'} \right) + |CI| \cdot \left(\overline{R_{u_j}'}^2 - \overline{R_{u_j}}^2 \right) \quad (3.18)$$

Če uporabnik u ima podatek o gledanosti stvari i_k , uporabnik u_j pa do sedaj podatka o gledanosti te stvari še ni imel, potem C posodobimo po enačbi 3.19.

$$C' = C + 2 \cdot \sum_{i \in CI} R_{u_j, i} \left(\overline{R_{u_j}} - \overline{R_{u_j}'} \right) + |CI| \cdot \left(\overline{R_{u_j}'}^2 - \overline{R_{u_j}}^2 \right) + \left(R_{u_j, i_k} - \overline{R_{u_j}'}^2 \right) \quad (3.19)$$

Če sta uporabnika u in u_j podatek o gledanosti stvari i_k že imela, potem C posodobimo po enačbi 3.20.

$$C' = C + 2 \cdot \sum_{i \in CI \setminus \{i_k\}} R_{u_j, i} \left(\overline{R_{u_j}} - \overline{R_{u_j}'} \right) + (|CI| - 1) \cdot \left(\overline{R_{u_j}'}^2 - \overline{R_{u_j}}^2 \right) - \left(R_{u_j, i_k} - \overline{R_{u_j}} \right)^2 + \left(R'_{u_j, i_k} - \overline{R_{u_j}'} \right)^2 \quad (3.20)$$

3.5.3 Inkrementalno posodabljanje D

Vrednost D se spremeni le v primeru, da ima uporabnik u podatek o gledanosti stvari i_k , u_j pa podatka o gledanosti te stvari do sedaj še ni imel. Izračun je podan v enačbi 3.21.

$$D' = D + \left(R_{u, i_k} - \overline{R_u} \right)^2 \quad (3.21)$$

3.5.4 Izdelava napovedi

Napoved za uporabnika u in stvar i naredimo tako, da izračunamo podobnosti po enačbi 3.14 (iz shranjenih vrednosti B , C in D) do vseh ostalih uporabnikov, ki imajo podatek o gledanosti stvari i . Nato vzamemo nekaj najbolj podobnih uporabnikov in njihovo gledanost stvari množimo s podobnostjo uporabnika uporabniku u . Produkte nato seštejemo in delimo z vsoto podobnosti. Tako dobimo napoved za uporabnika u in stvar i .

3.6 BRISMF

BRISMF pomeni *Biased Regularized Incremental Simultaneous Matrix Factorization* oziroma *pristranska regularizirana inkrementalna simultana matrična faktorizacija*. Kot že samo ime pove, metoda temelji na matrični faktorizaciji. Preferenčno matriko aproksimiramo z dvema matrikama (glej enačbo 3.22). Opis metode je povzet po viru [18].

$$R_{ui} \approx P_{uk} \cdot Q_{ki} \quad (3.22)$$

$$\begin{bmatrix} R_{11} & R_{12} & \cdots & R_{1i} \\ R_{21} & R_{22} & \cdots & R_{2i} \\ \vdots & \vdots & \ddots & \vdots \\ R_{u1} & R_{u2} & \cdots & R_{ui} \end{bmatrix} \approx \begin{bmatrix} P_{11} & \cdots & P_{1k} \\ P_{21} & \cdots & P_{2k} \\ \vdots & \ddots & \vdots \\ P_{u1} & \cdots & P_{uk} \end{bmatrix} \cdot \begin{bmatrix} Q_{11} & Q_{12} & \cdots & Q_{1i} \\ \vdots & \vdots & \ddots & \vdots \\ Q_{k1} & Q_{k2} & \cdots & Q_{ki} \end{bmatrix}$$

Parameter k predstavlja število latentnih spremenljivk. Manjše kot je to število, bolj metoda posplošuje. Večje kot je, bolj se metoda prilagaja učnim podatkom. Matrika P je matrika uporabnikov. Vsaka vrstica te matrike predstavlja profil nekega uporabnika. Q je matrika stvari, vsak stolpec iz te matrike predstavlja profil stvari. Poleg matrik P in Q moramo voditi še povprečje stvari \bar{R}_i in povprečno odstopanje uporabnika \bar{O}_u . To odstopanje dobimo tako, da ga pri vsakem novem podatku posodobimo z razliko nove gledanosti in povprečne gledanosti te stvari.

Če želimo izdelati napoved za uporabnika u in stvar i , moramo samo izračunati skalarni produkt ustrezne vrstice iz P in ustreznega stolpca iz Q . \bar{O}_u je povprečno odstopanje uporabnika glede na povprečje stvari. Napoved torej izdelamo po enačbi 3.23.

$$R_{u,i} = \bar{R}_i + \bar{O}_u + \sum_{1 \leq j \leq k} P_{u,j} \cdot Q_{j,i} \quad (3.23)$$

Matriki P in Q lahko izračunamo na več načinov. Pri metodi BRISMF ti dve matriki inicializiramo naključno, nato pa ju z gradientno metodo optimiziramo. Med učenjem modela se moramo nekajkrat sprehoditi čez učne podatke. Za vsak podatek izdelamo napoved z obstoječim modelom (\hat{R}_{ui}) in s pomočjo znanega podatka R_{ui} izračunamo napako e_{ui} (glej enačbo 3.24). Nato uporabniški profil iz matrike P ter profil stvari iz matrike Q popravimo (glej enačbi 3.25 in 3.26). Parameter η predstavlja hitrost učenja, λ pa predstavlja regularizacijski faktor, ki

zmanjšuje pretirano prilagajanje uĉnim podatkom.

$$e_{ui} = R_{ui} - \hat{R}_{ui} \quad (3.24)$$

$$\forall j \in \{x; 1 \leq x \leq k\} : p'_{uj} = p_{uj} + \eta(e_{ui} \cdot q_{ji} - \lambda \cdot p_{uj}) \quad (3.25)$$

$$\forall j \in \{x; 1 \leq x \leq k\} : q'_{ji} = q_{ji} + \eta(e_{ui} \cdot p_{uj} - \lambda \cdot q_{ji}) \quad (3.26)$$

Uporabniki in stvari so pristranske. To pomeni, da npr. obstajajo stvari, ki so vsem uporabnikom bolj všeĉ in obstajajo uporabniki, ki imajo povpreĉno gledanost vseh stvari višjo kot drugi. Metoda BRISMF to obravnava tako, da po posodobitvah po enaĉbah 3.25 in 3.26 prvi stolpec v matriki P nastavimo na vrednosti 1, isto pa naredimo tudi z ne-prvo (npr. zadnjo) vrstico matrike Q . Tako bo pri napovedovanju v skalarnem produktu en faktor odvisen le od uporabnika, eden pa le od stvari.

Parametre k , η in λ lahko doloĉimo na veĉ naĉinov. Mi smo vsem tem parametrom doloĉili moŹno zalogo vrednosti, nato pa uĉenje pognali z nakljuĉno izbranimi vrednostmi parametrov. Nakljuĉno izbranih 30% podatkov smo odstranili iz uĉne mnoŹice in z njimi preverili natanĉnost napovedi. To smo nekajkrat ponovili. ObdrŹali smo BRISMF model z najmanjšo napako RMSE na izvzetih podatkih.

Metoda BRISMF sama po sebi ni inkrementalna. To smo rešili tako, da gradimo BRISMF modele za kratka časovna obdobja, nato pa njihove napovedi zdruŹimo. Veĉ o tem v razdelku 3.7.

3.7 Naĉini uporabe metod za priporoĉanje

Metode opisane v razdelkih 3.2, 3.3, 3.4, 3.5 in 3.6 smo uporabljali v razliĉnih naĉinih; inkrementalno, agregirano in z oknom.

Inkrementalno pomeni, da za vsak dan z modelom izdelamo napovedi. Nato uporabimo podatke tega dne še za inkrementalno uĉenje. Enak postopek ponovimo na naslednjem dnevu. Modela nikoli ne gradimo ponovno na vseh podatkih.

Agregirano pomeni, da smo za vsak dan na podatkih vseh prejšnjih dni naenkrat zgradili en model. Modela nismo inkrementalno posodabljali, ampak smo za vsak naslednji dan zgradili nov model na vseh podatkih od zaĉetka.

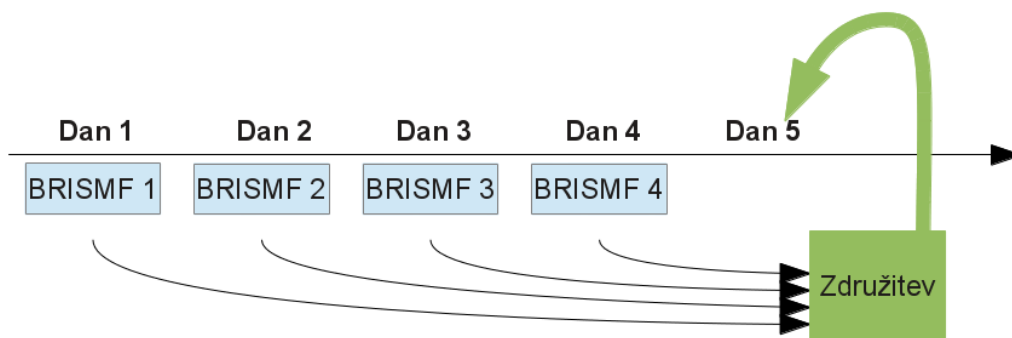
Z oknom pomeni, da smo za vsak dan vzeli podatke prejšnjih n dni in na njih naenkrat zgradili en model. Ta model smo uporabili za izdelavo napovedi za trenutni dan. Nato smo se pomaknili na naslednji dan in ponovili postopek.

Ne glede na način uporabe smo podatke brali za vsak dan posebej (glej razdelek 2.5).

3.7.1 Inkrementalni način

Na inkrementalni način smo pognali metode predstavljanje v tabeli 3.1. Napovedovanje in učenje je potekalo za vsak dan posebej.

Ker se modelov BRISMF ne da inkrementalno posodablјati, smo preizkusili alternativni pristop. Zasnovali smo metodo, ki za vsak dan zgradi model BRISMF. Za priporočanje vzamemo napovedi modelov prejšnjih dni in jih utežimo (priporočila, ki smo jih naredili s starejšim modelom imajo manjšo težo). Tako dobimo metodo, ki smo jo poimenovali *dnevni BRISMF*. Metoda je grafično prikazana na sliki 3.1.



Slika 3.1: Shema metode dnevni BRISMF

3.7.2 Agregirani način

Agregirani način pomeni, da smo za vsak dan, ko smo izvajali testiranje, zgradili modele na vseh podatkih prejšnjih dni naenkrat. V praksi to ni uporabno, saj je prepočasno. Tu smo ta način vseeno uporabili, tako da lahko primerjamo rezultate pridobljene z isto metodo na inkrementalni in agregirani način. Metode so

Tabela 3.1: Inkrementalni način

Metoda	Oznaka
dnevno povprečje	<i>avg_daily</i>
zgodovina	<i>history</i>
zgodovina s pozabljanjem	<i>forget_history</i>
zgodovina s pozabljanjem ob nedeljah	<i>forget_sunday_history</i>
dnevni kNN z zgodovino	<i>history_iknn_daily</i>
dnevni ECOCLE	<i>ecocle_daily</i>
dnevni kNN	<i>iknn_daily</i>
dnevni BRISMF	<i>brismf_daily</i>

predstavljene v tabeli 3.2.

Tabela 3.2: Agregirani način

Metoda	Oznaka
agregirano povprečje	<i>avg_daily_batch</i>
agregirani ECOCLE	<i>ecocle_daily_batch</i>
agregirani kNN	<i>iknn_daily_batch</i>
agregirani BRISMF	<i>brismf_daily_batch</i>

3.7.3 Okenski način

Metode, ki smo jih poganjali na okenski način so predstavljene v tabeli 3.3. Okenski način pomeni, da smo gradili modele na podatkih z več dni (dolžina okna). Okna so zamaknjena za 1 dan.

3.8 Priporočanje dejanskih oddaj

Ker moramo uporabnikom priporočiti dejanske oddaje, ne pa stvari, moramo obrazložiti še, kako smo priporočene stvari preslikali v oddaje. S priporočilnim sistemom smo izdelali napoved vsečnosti vseh stvari (za zelenega uporabnika), ki so

Tabela 3.3: Okenski način

Metoda	Oznaka
povprečje z oknom	<i>avg_window</i>
BRISMF z oknom	<i>brismf_window</i>

na sporedu na želeni dan. Iz seznama nato odstranimo vse, razen 1% napovedano najboljših stvari. Nato pripravimo seznam oddaj, ki so na sporedu na želeni dan in se preslikajo v stvari, ki smo jih ohranili. Izmed teh oddaj nato naključno izberemo n oddaj, ki jih uporabniku priporočimo.

Za uporabo 1% najboljših stvari smo se odločili, ker smo eksperimentalno ugotovili, da se pogosto zgodi, da ima več stvari enako napovedano vsečnost. Tako se izognemo dilemi izbiranja med enakovredno vsečnimi stvarmi.

Poglavje 4

Mere uspešnosti

4.1 Preciznost

Preciznost (*precision*) je ena izmed mer, s katerimi smo evalvirali delovanje različnih metod na naših podatkih. Preciznost smo definirali kot delež napovedanih stvari, ki so uporabniku dejansko vseč (glej enačbo 4.1). Množica R vsebuje stvari, ki smo jih uporabniku priporočili, množica T pa vsebuje stvari, ki so bile uporabniku vseč. Metoda je povzeta po viru [16].

$$p = \frac{|R \cap T|}{|R|} \quad (4.1)$$

Nato smo za vsako metodo za vsak dan rezultate povprečili preko vseh uporabnikov.

4.2 Priklic

Priklic (*recall*) je ena izmed mer, s katerimi smo evalvirali delovanje različnih metod na naših podatkih. Priklic smo definirali kot delež stvari, ki so bile uporabniku vseč in smo jih napovedali (enačba 4.2). Množica R vsebuje stvari, ki smo jih uporabniku priporočili, množica T pa vsebuje stvari, ki so bile uporabniku vseč. Metoda je povzeta po viru [16].

$$r = \frac{|R \cap T|}{|T|} \quad (4.2)$$

Nato smo za vsako metodo za vsak dan rezultate povprečili preko vseh uporabnikov.

4.3 RMSE

Kratica RMSE pomeni *Root Mean Squared Error* oziroma *koren povprečne kvadratne napake*. Metoda je povzeta po viru [8]. Je ena izmed mer, ki se zelo pogosto uporabljajo na področju priporočilnih sistemov, kljub temu pa morda za končnega uporabnika ni najbolj primerna.

Za vsak dan izdelamo napovedi za vse uporabnike in stvari, za katere imamo za ta dan na voljo gledanost. Nato izračunamo napake za vse napovedi, ki smo jih naredili. Te napake kvadriramo (s tem povečamo vpliv velikih in zmanjšamo vpliv majhnih napak), povprečimo, na koncu pa še korenimo (glej enačbo 4.3). T je testna množica, na kateri računamo RMSE. Ker smo evalvirali za vsak dan posebej je to torej množica vseh gledanosti stvari za trenutni dan. \hat{R}_{ui} je napoved vsečnosti stvari i za uporabnika u .


$$\text{RMSE} = \sqrt{\frac{1}{|T|} \sum_{(u,i,r) \in T} \left(\hat{R}_{ui} - r \right)^2} \quad (4.3)$$

Poglavje 5


Rezultati

5.1 Analiza podatkov


Vseh podatkov o ogledih oddaj, ki smo jih uporabili pri pripravi priporočilnega sistema je 438.626. Za vsak dan imamo na voljo v povprečju 14.621 podatkov (glej graf 5.1), to znaša približno 15 podatkov o gledanosti oddaj na uporabnika na dan. Te podatke nato preslikamo v stvari. Če uporabimo definicijo stvari A (stvar=[žanr]) potem to pomeni v povprečju 3 podatke o gledanosti stvari na dan (glej graf 5.2), sicer (uporaba definicije stvari B ali C) pa pride na uporabnika približno 11 podatkov o gledanosti stvari na dan (glej graf 5.3). Kot uporabniku vsečne stvari smo definirali tiste, pri katerih je njihova gledanost presegala njegovo povprečno gledanost za trenutni dan.



Slika 5.1: Število podatkov o ogledih oddaj na dan, od 1.6.2013 do 30.6.2013



Slika 5.2: Število podatkov o gledanosti stvari na uporabnika na dan, definicija stvari A, od 1.6.2013 do 30.6.2013



Slika 5.3: Število podatkov o gledanosti stvari na uporabnika na dan, definiciji stvari B ali C, od 1.6.2013 do 30.6.2013


5.2 Primerjava okusa glede na dan v tednu

Zanima nas, ali imajo uporabniki med tednom drugačen okus, kot ga imajo ob koncih tedna.

Uporabimo definicijo stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`). Za vse uporabnike za vsak dan pridobimo stvari, ki so jim všeč. Te podatke pridobimo za časovno obdobje od 1.6.2013 do 30.6.2013. Tako imamo za vsak dan za vsakega uporabnika množico njemu všečnih stvari. Za vsakega uporabnika nato množice stvari z operacijo unije združimo glede na dan v tednu. Sedaj imamo za vsakega uporabnika za vsak dan v tednu množico stvari, ki so mu všeč. Za vsakega uporabnika za vse kombinacije parov dni na množicah všečnih stvari izračunamo Jaccardov index (razdelek 3.1). Te nato povprečimo preko vseh uporabnikov. Tako dobimo korelacijsko matriko prikazano na sliki 5.4. Na matriki vidimo, da je povprečna podobnost množic med tednom večja kot, če primerjamo dan v tednu z dnem ob koncu tedna. Vpliv konca tedna je jasno viden. Stvari, ki so uporabnikom všeč ob ponedeljkih, so precej bolj podobne stvarjem, ki

so uporabnikom vseh npr. ob četrtnih kot pa ob sobotah.

Zato smo se odločili, da bomo poleg enostavne definicije A (`stvar=[žanr]`) uvedli še dve, pri katerih ena upošteva ali je oddaja na sporedu ob koncu tedna (definicija stvari B) ali ne (definicija stvari C). Bolj podroben opis definicij stvari je v razdelku 2.3.



Slika 5.4: Korelacijska matrika okusa uporabnikov glede na dan v tednu

5.3 Rezultati evalvacije

V tem razdelku so predstavljeni rezultati evalvacije. Točne oznake posameznih metod so na voljo v razdelku 3.7. Točni parametri, s katerimi smo izdelali napovedi


so v dodatku B. Definicije stvari (atributnega opisa) so podane v razdelku 2.3. Učenje smo izvajali na podatkih z obdobja od 1.6.2013 do 30.6.2013. Rezultate evalvacije imamo torej za obdobje od 2.6.2013 do 30.6.2013. Naj omenimo, da je bila 2.6.2013 nedelja.

V eksperimentih, kjer smo uporabili definicijo stvari A, smo uporabniku za vsak dan priporočili 3 najboljše stvari in 3 najboljše oddaje ter evalvacijo izvajali na teh priporočilih. Kjer smo uporabili definiciji stvari B in C, smo za vsakega uporabnika za vsak dan priporočili 8 najboljših stvari in 8 najboljših oddaj.

Rezultati priklica so pomembnejši od preciznosti, saj je oddaj, ki so uporabniku všeč malo. V teh primerih je priklic primernejša mera od preciznosti.

5.3.1 Napovedi stvari


Slika 5.5: Preciznost napovedi stvari za vsak dan evalvacije pri definiciji stvari A



Na grafu preciznosti pri definiciji stvari A (slika 5.5) vidimo, da so med metodami z najvišjo preciznostjo metode: *povprečje z oknom* (*avg_window*), *BRISMF z oknom* (*brismf_window*), *zgodovina s pozabljanjem* (*forget_history*), *zgodovina s pozabljanjem ob nedeljah* (*forget_sunday_history*), *zgodovina* (*history*). V povprečju


Slika 5.6: Preciznost napovedi stvari za vsak dan evalvacije pri definiciji stvari

B



Slika 5.7: Preciznost napovedi stvari za vsak dan evalvacije pri definiciji stvari

C



je najboljša metoda *zgodovina s pozabljanjem* (*forget_history*). Metode pograne na agregiran način ne dajejo dobrih rezultatov.


Na grafu preciznosti pri definiciji stvari B (slika 5.6) in C (slika 5.7) vidimo, da so med metodami z daleč najvišjo preciznostjo metode, ki temeljijo na zgodovini. Kot najboljšo bi izpostavili metodo *zgodovina s pozabljanjem* (*forget_history*). *Zgodovina s pozabljanjem ob nedeljah* (*forget_sunday_history*) sicer daje še boljše rezultate, a ni tako konsistentna kot *zgodovina s pozabljanjem*. Preciznost najboljše metode je ob uporabi definicije, ki upošteva konec tedna (B) višja, kot če se konca tedna ne upošteva posebej (definicija C). Rezultati metode *dnevni BRISMF* so slabši, a se čez celotno obdobje izboljšujejo.

Pri metodi *zgodovina s pozabljanjem ob nedeljah* (*forget_sunday_history*) je še posebej lepo viden vpliv uporabe vikenda v časovnem opisu oddaje. Če ga uporabimo in pozabimo vse podatke v nedeljo, ob začetku dneva, dobimo slabe rezultate za nedeljo in ponedeljek. Za ponedeljek so rezultati slabi zato, ker se vse oddaje v nedeljo preslikajo v stvari, ki imajo v časovnem opisu vrednost večjo od 10 (konec tedna). Večina izmed oddaj na sporedu v ponedeljek nima vrednosti večje od 10 (razen tistih, ki so se začele v nedeljo). Posledično so rezultati za ponedeljek slabi, saj ne poznamo gledanosti nobene izmed stvari, ki so na sporedu med tednom. Pri definiciji stvari C imamo slab rezultat samo v nedeljo, saj za ponedeljek že imamo podatke o gledanosti stvari, ki smo jih pridobili v nedeljo. Rezultati metode *dnevni BRISMF* (*brismf_daily*) se s časom izboljšujejo. Ob koncu testnega obdobja je metoda najboljša od ne-zgodovinskih metod.


Na grafu priklica pri definiciji stvari A (slika 5.8) vidimo, da so najboljše metode, ki temeljijo na zgodovini: *zgodovina s pozabljanjem v nedeljo* (*forget_sunday_history*), *zgodovina s pozabljanjem* (*forget_history*), *zgodovina* (*history*). Od metod, ki ne temeljijo na zgodovini sta najboljši metodi *povprečje z oknom* (*avg_window*), *BRISMF z oknom* (*brismf_window*).

Na grafih priklica pri definicijah stvari B in C (sliki 5.9 in 5.10) vidimo, da so najboljše metode tiste, ki temeljijo na zgodovini. Najboljši metodi sta *zgodovina s pozabljanjem* (*forget_history*) in *zgodovina s pozabljanjem ob nedeljah* (*forget_sunday_history*). Pri definiciji stvari B ima najboljša metoda boljši priklic kot pri definiciji stvari C. Rezultati so torej podobni kot pri primerjavi grafov preciznosti.


Slika 5.8: Priklic napovedi stvari za vsak dan evalvacije pri definiciji stvari A



Slika 5.9: Priklic napovedi stvari za vsak dan evalvacije pri definiciji stvari B



Slika 5.10: Priklic napovedi stvari za vsak dan evalvacije pri definiciji stvari C



Kljub temu so rezultati priklica pomembnejši od preciznosti, ker je uporabniku vsak dan vseh relativno malo stvari. Če bi npr. za vsak dan uporabniku napovedali vse možne stvari, bi bila preciznost še vedno slaba, uporabnik pa bi kljub temu dobil priporočila za vse stvari, ki so mu vseh.

Pri definicijah stvari B in C opazimo, da je *zgodovina* (*history*) slabša od *zgodovine s pozabljanjem* (*forget_history*). Pri definiciji stvari A to ni tako izrazito, saj se tukaj več oddaj preslika v isto stvar in je stvari manj. Stvari se pogosteje ponavljajo in tako se stari zgodovinski podatki prepišejo z novimi. To ima za posledico pozabljanje.


5.3.2 Napovedi nepričakovanih stvari

Metode, ki temeljijo na zgodovini, priporočajo stvari, ki so bile uporabniku v preteklih dneh vseh. Tako uporabniku nikoli ne priporočamo nobene stvari, ki je še ni gledal. Eden izmed ciljev pa je, da bi uporabniku priporočali tudi stvari, ki jih še ne pozna, a mu bodo vseeno vseh.

Ker so se metode, ki temeljijo na zgodovini, izkazale za zelo dobre (glej razdelek 5.3.1) smo se odločili narediti evalvacijo še tako, da izmed napovedanih stvari

in izmed stvari, ki so bile uporabniku všeč odstranimo vse, kar napove metoda *zgodovina s pozabljanjem(forget_history)*. S takim pristopom želimo ugotoviti, katera od metod je najboljša pri priporočanju stvari, ki jih uporabnik še ne pozna. Želimo mu priporočati stvari, ki mu bodo še vedno všeč, a bodo drugačne od tistih, ki so mu bile všeč v prejšnjih dneh.


Slika 5.11: Preciznost napovedi nepričakovanih stvari za vsak dan evalvacije pri definiciji stvari A




Na sliki 5.11 je prikazana preciznost napovedi nepričakovanih stvari pri definiciji stvari A. Vidimo, da so najboljše metode *BRISMF* z oknom (*brismf_window*), povprečje z oknom (*avg_window*), dnevni *BRISMF* (*brismf_daily*), dnevno povprečje (*avg_daily*). Metodi z oknom dajeta nekoliko nekonsistentne rezultate.

Na slikah 5.12 in 5.13 sta prikazana grafa preciznosti napovedi nepričakovanih stvari pri definicijah stvari B in C. Vidimo, da so najboljše metode dnevni *BRISMF* (*brismf_daily*), *BRISMF* z oknom (*brismf_window*) in dnevno povprečje (*avg_daily*). Od teh metod je še najboljša metoda dnevni *BRISMF* (*brismf_daily*), saj je skoraj vsak dan preciznost te metode najvišja. Na sliki 5.12 vidimo, da je preciznost ob koncih tedna manjša kot sicer, kar je še posebej očitno pri uporabi definicije stvari B. To je posledica dejstva, da je v obdobju evalvacije več delovnih dni kot pa vikendov (pri definiciji stvari B striktno ločimo med oddajami na sporedu ob

Slika 5.12: Preciznost napovedi nepričakovanih stvari za vsak dan evalvacije pri definiciji stvari B




Slika 5.13: Preciznost napovedi nepričakovanih stvari za vsak dan evalvacije pri definiciji stvari C



koncu tedna in ostalimi). Pri uporabi definicije stvari C je to posledica drugačnega okusa uporabnikov ob koncih tedna. Če gledamo preciznost samo koncev tedna vidimo, da tudi ta narašča.


Slika 5.14: Priklic napovedi nepričakovanih stvari za vsak dan evalvacije pri definiciji stvari A




Na sliki 5.14 je graf priklica napovedi nepričakovanih stvari pri uporabi definicije stvari A. Najboljše metode so iste kot pri preciznosti napovedi nepričakovanih stvari (slika 5.11).

Na slikah 5.15 in 5.16 sta grafa priklica napovedi nepričakovanih stvari pri uporabi definicij stvari B in C. Najboljše metode so *dnevni BRISMF* (*brismf_daily*), *BRISMF z oknom* (*brismf_window*) in *dnevno povprečje* (*avg_daily*). Iste metode so najboljše tudi na grafih preciznosti nepričakovanih stvari pri definicijah stvari B in C. V obeh primerih opazimo, da so rezultati boljši pri definiciji stvari C, za razliko od rezultatov evalvacije napovedi vseh stvari (ne samo nepričakovanih, glej razdelek 5.3.1). To je posledica slabšega delovanja metode *zgodovina s pozabljanjem* (*forget_history*) na definiciji stvari C.

Slika 5.15: Priklic napovedi nepričakovanih stvari za vsak dan evalvacije pri definiciji stvari B




Slika 5.16: Priklic napovedi nepričakovanih stvari za vsak dan evalvacije pri definiciji stvari C



5.3.3 RMSE napovedi stvari

Slika 5.17: RMSE napovedi stvari za vsak dan evalvacije pri definiciji stvari


A



Na slikah 5.17, 5.18, 5.19 so grafi, ki prikazujejo RMSE pri definicijah stvari A, B, in C. Opazimo, da so vrednosti RMSE pri definiciji stvari A višje kot pri ostalih definicijah stvari. To je zato, ker je tu več oddaj združenih v eno stvar kot pri ostalih definicijah stvari in posledično je težje napovedati gledanost stvari. Na vseh grafih opazimo, da imajo zgodovinske metode RMSE najvišji in so tako najslabše. Pri preciznosti in priklicu pa so ravno te metode najboljše. Tu vidimo, da je potrebno dobro izbrati mero za določanje kakovosti priporočil. Uporabnika namreč ne zanima numerična vrednosti predvidene gledanosti, zanima ga samo katere oddaje mu bodo všeč, za to pa sta preciznost in priklic boljši meri.


Slika 5.18: RMSE napovedi stvari za vsak dan evalvacije pri definiciji stvari

B



Slika 5.19: RMSE napovedi stvari za vsak dan evalvacije pri definiciji stvari

C




5.3.4 Napovedi oddaj

Rezultati napovedi oddaj niso pretirano merodajni. Priporočilni sistem namreč za vsakega uporabnika za vsak dan izdela priporočila za stvari. Ta seznam priporočenih stvari je nato potrebno preslikati v dejanske oddaje. Pri tem si pomagamo s sporedom. Vsak dan pa je na sporedu zelo veliko oddaj, ki se preslikajo v isto stvar. Preciznost in priklic sta posledično slaba, ker uporabnik sploh ne ve, da oddaja, ki smo jo priporočili, obstaja.

Ob predpostavki, da velik delež uporabnikov spremlja le nekaj TV programov, bi se preciznost in priklic oddaj (pa tudi stvari) verjetno izboljšala, če bi v definicijo stvari vključili še TV program, na katerem je na sporedu oddaja. Tako bi ugotovili, katere TV programe uporabnik spremlja. Tega načrtno nismo naredili, saj želimo uporabniku ponuditi tudi oddaje, ki jih ne pozna, na TV programih, ki jih ne pozna.


Slika 5.20: Preciznost napovedi oddaj za vsak dan evalvacije pri definiciji stvari A




Na slikah 5.20, 5.21, 5.22 so grafi preciznosti napovedi oddaj pri definicijah stvari A, B in C. Na slikah 5.23, 5.24, 5.25 so grafi priklica napovedi oddaj pri definicijah stvari A, B in C.

Pričakovano se tudi na grafih preciznosti in priklica napovedi oddaj izkaže,

Slika 5.21: Preciznost napovedi oddaj za vsak dan evalvacije pri definiciji stvari B




Slika 5.22: Preciznost napovedi oddaj za vsak dan evalvacije pri definiciji stvari C




Slika 5.23: Priklic napovedi oddaj za vsak dan evalvacije pri definiciji stvari

A




Slika 5.24: Priklic napovedi oddaj za vsak dan evalvacije pri definiciji stvari

B



Slika 5.25: Priklic napovedi oddaj za vsak dan evalvacije pri definiciji stvari C



da so najboljše metode, ki temeljijo na zgodovini. Pri uporabi definicije stvari A vidimo, da so preciznosti in priklici oddaj še posebej slabe. To je zato, ker se v vsako stvar preslika zelo veliko oddaj. Tako je težko preslikati seznam stvari, ki jih priporočamo, v dejanski seznam oddaj, ki jih priporočamo uporabniku. Pri uporabi definicij stvari B in C so rezultati nekoliko boljši. V posamezno stvar se preslika manj oddaj. Najboljše metode so *zgodovina s pozabljanjem ob nedeljah* (*forget_sunday_history*) in *zgodovina s pozabljanjem* (*forget_history*). Pri uporabi definicije stvari B so rezultati v povprečju boljši, kar še potrjuje našo ugotovitev, da imajo uporabniki ob koncu tedna drugačen okus kot ob delavnikih.

Poglavje 6

Zaključek

Ugotovili smo, da je priporočanje stvari in še posebej oddaj, ki bodo uporabniku vseh, težek problem. Podatki so šumni, o oddajah pa imamo na voljo malo podatkov.

Kot najboljša se je izkazala definicija stvari B (`stvar = [žanr, leto izdelave, jezik, časovni opis z vikendom]`). Pri rezultatih evalvacije napovedi nepričakovanih stvari (glej 5.3.2) so rezultati sicer boljši pri definiciji stvari C, vendar je razlog v tem, da *zgodovina s pozabljanjem*, ki jo uporabljamo pri definiranju *nepričakovanih* stvari, deluje slabše pri definiciji stvari C in posledično izgleda, kot da vse druge metode pri slednji definiciji stvari delujejo bolje.

Originalni prispevki tega dela so metoda *dnevni BRISMF* (razdelek 3.7.1) ter sama implementacija in evalvacija vseh ostalih v poglavju 3 opisanih metod. Metoda *dnevni BRISMF*, ki smo jo zasnovali, daje v primerjavi z drugimi metodami dobre rezultate. Najboljšja je pri priporočanju *nepričakovanih* stvari. Tudi pri ostalih testih je med boljšimi, boljše so le tiste metode, ki temeljijo direktno na zgodovini.

Ugotovili smo, da bi na teh podatkih lahko dosegli še boljše rezultate s kombiniranjem metod *zgodovina s pozabljanjem* in *dnevni BRISMF*. Uporabniku bi priporočali nekaj oddaj, ki jih priporoči prva in nekaj oddaj, ki jih priporoči druga metoda.

Izkazalo se je, da so metode pognane v inkrementalnem načinu, boljše od tistih v agregiranem načinu. Do tega pride zato, ker se okus uporabnika skozi čas spreminja. Pri vseh inkrementalnih metodah smo uporabili neko obliko pozabljanja,

ki je pomembna sestavina inkrementalnega učenja. Stari podatki o ogledih oddaj namreč niso več tako zanesljivi, saj se je okus uporabnika vmes lahko že spremenil. Podoben trend lahko opazimo, če primerjamo rezultate metode *zgodovina (history)* in *zgodovina s pozabljanjem (forget_history)*.

V nadaljnjem delu bi se dalo priporočila do neke mere izboljšati tudi tako, da bi za različne tipe oddaj pripravili različne priporočilne sisteme. Priporočilni sistem za filme in serije bi lahko dodatne podatke pridobival s pomočjo raznih spletnih zbirk. Sistem za serije bi lahko upošteval dejstvo, da si deli serije sledijo. Če nekdo gleda nekaj zaporednih delov, mu je serija verjetno všeč. Poiščemo lahko podobne serije in mu jih priporočimo. Nekomu, ki gleda informativno oddajo na nekem določenem programu, bi lahko priporočili informativne oddaje na drugih programih. Tako omilimo težavo, ki jo povzročijo vsak dan nove oddaje. S tem se zaenkrat nismo ukvarjali, saj smo želeli pripraviti čim bolj univerzalni priporočilni sistem, ki potrebuje čim manj podatkov o stvareh, ki jih priporoča, obenem pa zna priporočati tudi oddaje, ki se ne ponavljajo.

Literatura

- [1] T. George, S. Merugu, “A Scalable Collaborative Filtering Framework based on Co-clustering”, v zborniku *Fifth IEEE Conference on Data Mining*, Houston, Houston, ZDA, sept. 2005, str. 625-628
- [2] M. Jahrer, A. Toscher, R. Legenstein, “Combining Predictions for Accurate Recommender Systems”, v zborniku *KDD '10 Proceedings of the 16th ACM SIGKDD international conference on Knowledge discovery and data mining*, str. 693-702, 2010
- [3] D. Jannach, M. Zanker, A. Felfernig, G. Friedrich, “Recommender Systems: An Introduction”. New York: Cambridge University Press, 2011. ISBN 978-0-521-49336-9
- [4] M. Khoshneshin, W. Nick Street, “Incremental Collaborative Filtering via Evolutionary Co-clustering”, v zborniku *RecSys2010*, Barcelona, Španija, sept. 2010, str. 325-328
- [5] Y. Koren, R. Bell, C. Volinsky, “Matrix factorization techniques for recommender systems”, v reviji: *IEEE Computer*, str. 42-49, avgust 2009
- [6] C. Krauss, L. George, S. Arbanowski, “TV Predictor: Personalized Program Recommendations to be displayed on SmartTVs”, v zborniku *BigMine'13*, Chicago, ZDA, avgust 2013, str 63-70
- [7] M. Papagelis, I. Rousidis, D. Plexousakis, E. Theoharopoulos, “Incremental Collaborative Filtering for Highly-Scalable Recommendation Algorithms”, v zborniku *Proceedings of the 15th International Symposium on Methodologies of Intelligent Systems*, Saratoga Springs, New York, ZDA, maj 2005, str. 553-561

-
- [8] G. Takacs, I. Pilaszy, B. Nemeth, D. Tikk, "Scalable Collaborative Filtering Approaches for Large Recommender Systems", v zborniku: *Journal of Machine Learning Research*, zv. 10, str. 623-656, 12.1.2009
 - [9] Y. Zhang, W.Chen, Z. Yin, "Collaborative filtering with social regularization for TV program recommendation", v reviji *Knowledge-based systems*, številka 54, str. 310-317, oktober 2013
 - [10] A. Yarali, A. Cherry, "Internet Protocol Television (IPTV)", v zborniku *IEEE TENCON05*, 2005, Melbourne, Avstralija, 1-6
 - [11] B. Sarwar, G. Karypis, J. Konstan, J. Riedl, "Item-based Collaborative Filtering Recommendation Algorithms", v zborniku *Proceedings of the 10th International Conference on World Wide Web*, Hong Kong, Hong Kong, str. 285-295, 2001
 - [12] X. Su, T. M. Khoshgoftaar, "A Survey of Collaborative Filtering Techniques", v zborniku *Adv. in Artif. Intell.*, New York, ZDA, str. 4:2-4:2, januar 2009
 - [13] N. Chang, M. Irvan, T. Terano, "A TV program recommender framework", v zborniku *17th International Conference in Knowledge Based and Intelligent Information and Engineering Systems - KES2013*, 2013, URL: <http://www.sciencedirect.com/science/article/pii/S1877050913009290>
 - [14] K. Kurapati, S. Gutta, D. Schaffer, J. Martino, J. Zimmerman, "A Multi-Agent TV Recommender", na konferenci *User Modeling*, v zborniku *Proceedings of the User Modeling 2001 workshop "Personalization in Future TV"*
 - [15] A. Martínez, J. Arias, A. Vilas, D. J. Garcia, N. M. Lopez, "What's on TV Tonight? An Efficient and Effective Personalized Recommender System of TV Programs", v *IEEE Transactions on Consumer Electronics*, 55(1), str. 286-294, 2009
 - [16] J. Herlocker, J. A. Konstan, L. G. Terveen, J. T. Reidl, "Evaluating Collaborative Filtering Recommender Systems", v zborniku *ACM Trans. Inf. Syst.*, št. 1, zvezek 22, strani 5-53, januar 2004

-
- [17] J. B. Schafer, D. Frankowski, J. Herlocker, S. Sen, “Collaborative Filtering Recommender Systems”, v knjigi *The Adaptive Web*, zvezek 4321, strani 291-324, Springer Berlin Heidelberg, 2007
- [18] I. Avbelj, “Hibridizacija priporočilnih sistemov temelječih na skupinskem izbiranju”, diplomsko delo, mentor: akad. prof. dr. Ivan Bratko, Fakulteta za računalništvo in informatiko Univerze v Ljubljani, Ljubljana, 2012, URL: <http://eprints.fri.uni-lj.si/1868/>

Dodatek A

Možne vrednosti atributov

A.1 Žanr

Možne vrednosti atributa žanr so: *None*, action, action-serial, action-series, adventure, adventure-serial, adventure-series, animated-film, animated-serial, animated-series, art, athletics, badminton, biographical-film, biographical-serial, biographical-series, biography, boxing, cartoon, comedy, consulting-show, cooking-show, crime, crime-serial, crime-series, culture, cycling, daily-news-show, documentary, documentary-film, drama, drama-serial, drama-series, entertainment-show, football, golf, gymnastics, handball, historical-series, history, hockey, horror, horror-series, interview, motocross, movie, music-documentary, music-film, music-show, natural-science, news-show, performance, ples, popular-science, quiz, religious-ritual, religious-show, rowing, rugby, sailing, sci-fi, sci-fi-serial, serial, series, short-film, skating, swimming, table-tennis, talk-show, teen-show, teen-talk-show, tennis, thriller, thriller-serial, thriller-series, traffic, travel, tv-show, volleyball, war, war-serial, war-series, weather, western, western-serial, western-series.

A.2 Leto izdelave

Leta izdelave so zaokrožena na 10. Možne vrednosti atribura so: 1910, 1920, 1930, 1940, 1950, 1960, 1970, 1980, 1990, 2000, 2010.

A.3 Jezik

Možne vrednosti atribura jezik so: afr, ara, bos, bul, cze, dan, deu, ell, eng, est, fin, fra, heb, hrv, hun, ice, ita, jpn, kor, mac, nld, nor, per, pol, por, ron, rus, slv, spa, srp, swe, tha, tur, zho.

Dodatek B

Rezultati evalvacije

B.1 Rezultati evalvacije pri definiciji stvari A

B.1.1 Metoda avg_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 3
- `nbest_products`: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0021, 0.0918, 0.0004, 0.0501, 0.0291, 0.0957, 0.0339, 0.0389, 0.0510, 0.1280, 0.1235, 0.1198, 0.1320, 0.1515, 0.1311, 0.1402, 0.1348, 0.1380, 0.1385, 0.1311, 0.1483, 0.1366, 0.1554, 0.1493, 0.1585, 0.1518, 0.1425, 0.1471, 0.1278]
- `hist_item_recalls`: [0.0023, 0.1059, 0.0004, 0.0808, 0.0572, 0.1528, 0.0545, 0.0625, 0.0797, 0.1935, 0.1924, 0.1778, 0.2020, 0.2255, 0.2056, 0.2222, 0.2113, 0.2063, 0.2182, 0.2006, 0.2268, 0.1962, 0.2233, 0.2044, 0.2295, 0.2322, 0.2111, 0.2230, 0.1850]

- **itemRMSE:** [0.3750, 0.3456, 0.3478, 0.3434, 0.3338, 0.3425, 0.3597, 0.3595, 0.3447, 0.3401, 0.3451, 0.3359, 0.3234, 0.3562, 0.3673, 0.3365, 0.3374, 0.3416, 0.3403, 0.3451, 0.3597, 0.3694, 0.3525, 0.3618, 0.3438, 0.3509, 0.3384, 0.3534, 0.3644]
- **item_precisions:** [0.0031, 0.1122, 0.0004, 0.1508, 0.1288, 0.1945, 0.0855, 0.0975, 0.1422, 0.2057, 0.2105, 0.1948, 0.2072, 0.1756, 0.1564, 0.2004, 0.2101, 0.2118, 0.2151, 0.2007, 0.1674, 0.1641, 0.2232, 0.2085, 0.2282, 0.2176, 0.2108, 0.1722, 0.1526]
- **item_recalls:** [0.0035, 0.1538, 0.0003, 0.2064, 0.1800, 0.2902, 0.1232, 0.1307, 0.1854, 0.2990, 0.3161, 0.2872, 0.3054, 0.2613, 0.2409, 0.2863, 0.2980, 0.2973, 0.3064, 0.2903, 0.2625, 0.2374, 0.2860, 0.2739, 0.3118, 0.3173, 0.3106, 0.2720, 0.2248]
- **product_precisions:** [0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0021, 0.0011, 0.0035, 0.0032, 0.0014, 0.0025, 0.0028, 0.0021, 0.0018, 0.0011, 0.0018, 0.0018, 0.0018, 0.0014, 0.0035, 0.0018, 0.0022, 0.0007, 0.0018, 0.0024, 0.0014, 0.0000, 0.0015, 0.0014]
- **product_recalls:** [0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0029, 0.0011, 0.0041, 0.0032, 0.0010, 0.0027, 0.0026, 0.0018, 0.0024, 0.0012, 0.0012, 0.0032, 0.0024, 0.0012, 0.0050, 0.0016, 0.0024, 0.0014, 0.0026, 0.0018, 0.0011, 0.0000, 0.0026, 0.0020]

B.1.2 Metoda avg_daily_batch

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (**stvar=[žanr]**) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 3
- **nbest_products:** 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0021, 0.0007, 0.0000, 0.0018, 0.0000, 0.0000, 0.0007, 0.0014, 0.0074, 0.0312, 0.0256, 0.0253, 0.0250, 0.0071, 0.0156, 0.0314, 0.0292, 0.1380, 0.0283, 0.0247, 0.0143, 0.0193, 0.0067, 0.0060, 0.1585, 0.0046, 0.1425, 0.1471, 0.1278]
- **hist_item_recalls:** [0.0023, 0.0010, 0.0000, 0.0035, 0.0000, 0.0000, 0.0011, 0.0025, 0.0120, 0.0519, 0.0386, 0.0384, 0.0399, 0.0106, 0.0252, 0.0538, 0.0479, 0.2063, 0.0494, 0.0403, 0.0212, 0.0289, 0.0125, 0.0089, 0.2295, 0.0083, 0.2111, 0.2230, 0.1850]
- **itemRMSE:** [0.3750, 0.3454, 0.3476, 0.3441, 0.3338, 0.3432, 0.3583, 0.3591, 0.3443, 0.3399, 0.3449, 0.3363, 0.3239, 0.3559, 0.3665, 0.3365, 0.3376, 0.3414, 0.3406, 0.3446, 0.3597, 0.3685, 0.3532, 0.3604, 0.3431, 0.3505, 0.3383, 0.3526, 0.3636]
- **item_precisions:** [0.0031, 0.0010, 0.0000, 0.0021, 0.0000, 0.0000, 0.0007, 0.0014, 0.0077, 0.1238, 0.1249, 0.1177, 0.1152, 0.0071, 0.0593, 0.1109, 0.1225, 0.2118, 0.1287, 0.1126, 0.0625, 0.0721, 0.0067, 0.0060, 0.2282, 0.0046, 0.2108, 0.1722, 0.1526]
- **item_recalls:** [0.0035, 0.0013, 0.0000, 0.0025, 0.0000, 0.0000, 0.0008, 0.0013, 0.0083, 0.1692, 0.1740, 0.1653, 0.1573, 0.0081, 0.0808, 0.1475, 0.1652, 0.2973, 0.1761, 0.1519, 0.0846, 0.0961, 0.0088, 0.0066, 0.3118, 0.0047, 0.3106, 0.2720, 0.2248]
- **product_precisions:** [0.0003, 0.0000, 0.0000, 0.0004, 0.0000, 0.0007, 0.0004, 0.0004, 0.0000, 0.0000, 0.0000, 0.0011, 0.0005, 0.0000, 0.0000, 0.0000, 0.0000, 0.0021, 0.0010, 0.0000, 0.0000, 0.0000, 0.0000, 0.0005, 0.0031, 0.0000, 0.0004, 0.0011, 0.0018]
- **product_recalls:** [0.0005, 0.0000, 0.0000, 0.0002, 0.0000, 0.0012, 0.0003, 0.0002, 0.0000, 0.0000, 0.0000, 0.0004, 0.0004, 0.0000, 0.0000, 0.0000, 0.0000, 0.0027, 0.0005, 0.0000, 0.0000, 0.0000, 0.0000, 0.0005, 0.0033, 0.0000, 0.0004, 0.0018, 0.0022]

B.1.3 Metoda avg_window

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 3
- `window_length`: 7 dni
- `nbest_products`: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0007, 0.0014, 0.0387, 0.0798, 0.0589, 0.0733, 0.0768, 0.0589, 0.2603, 0.0868, 0.0793, 0.2617, 0.0747, 0.0754, 0.0570, 0.2555, 0.1056, 0.0890, 0.2932, 0.0850, 0.0887, 0.0653, 0.2486]
- `hist_item_recalls`: [0.0011, 0.0025, 0.0662, 0.1114, 0.0784, 0.1025, 0.1052, 0.0775, 0.2741, 0.1182, 0.1073, 0.2677, 0.1022, 0.1014, 0.0699, 0.2538, 0.1316, 0.1049, 0.2938, 0.1168, 0.1128, 0.0812, 0.2535]
- `itemRMSE`: [0.3664, 0.3659, 0.3491, 0.3447, 0.3493, 0.3386, 0.3248, 0.3622, 0.3734, 0.3387, 0.3404, 0.3431, 0.3442, 0.3500, 0.3647, 0.3758, 0.3573, 0.3659, 0.3475, 0.3543, 0.3409, 0.3560, 0.3711]
- `item_precisions`: [0.0007, 0.0014, 0.1538, 0.2649, 0.2663, 0.2672, 0.2653, 0.1998, 0.3028, 0.2709, 0.2826, 0.3702, 0.2784, 0.2702, 0.1884, 0.2904, 0.2898, 0.2663, 0.3795, 0.2701, 0.2877, 0.2076, 0.2943]
- `item_recalls`: [0.0008, 0.0013, 0.2284, 0.3890, 0.4006, 0.4081, 0.3824, 0.2935, 0.4707, 0.3938, 0.4031, 0.5292, 0.3993, 0.4079, 0.2814, 0.4245, 0.3689, 0.3524, 0.5246, 0.3971, 0.4357, 0.3202, 0.4441]
- `product_precisions`: [0.0000, 0.0007, 0.0000, 0.0000, 0.0000, 0.0011, 0.0005, 0.0000, 0.0004, 0.0000, 0.0000, 0.0000, 0.0010, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0003, 0.0000, 0.0004, 0.0004, 0.0014]

- `product_recalls`: [0.0000, 0.0006, 0.0000, 0.0000, 0.0000, 0.0004, 0.0004, 0.0000, 0.0002, 0.0000, 0.0000, 0.0000, 0.0005, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0001, 0.0000, 0.0005, 0.0002, 0.0013]

B.1.4 Metoda brismf_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja [1e-1, 1e-4]
- `k`: naključno z območja [5, 50]
- `m`: naključno z območja [1e-1, 1e-3]
- `nbest_items`: 3
- `learn_rate`: naključno z območja [1e-2, 1e-4]
- `nbest_products`: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0553, 0.0399, 0.0240, 0.0613, 0.0393, 0.0992, 0.1151, 0.1184, 0.1109, 0.1332, 0.1254, 0.1202, 0.1341, 0.1508, 0.1305, 0.1402, 0.1343, 0.1377, 0.1382, 0.1312, 0.1483, 0.1366, 0.1554, 0.1493, 0.1585, 0.1518, 0.1425, 0.1484, 0.1294]
- `hist_item_recalls`: [0.0703, 0.0551, 0.0454, 0.0959, 0.0752, 0.1563, 0.1737, 0.1717, 0.1742, 0.1937, 0.1914, 0.1778, 0.2029, 0.2223, 0.2051, 0.2222, 0.2111, 0.2058, 0.2172, 0.2006, 0.2268, 0.1962, 0.2233, 0.2044, 0.2295, 0.2322, 0.2111, 0.2238, 0.1853]
- `itemRMSE`: [0.4184, 0.3636, 0.3613, 0.3521, 0.3406, 0.3494, 0.3596, 0.3622, 0.3453, 0.3409, 0.3444, 0.3385, 0.3249, 0.3558, 0.3657, 0.3375, 0.3364, 0.3432, 0.3392, 0.3441, 0.3565, 0.3669, 0.3494, 0.3583, 0.3413, 0.3468, 0.3367, 0.3511, 0.3628]

- `item_precisions`: [0.0924, 0.0693, 0.0771, 0.1691, 0.1396, 0.2018, 0.1663, 0.1712, 0.1982, 0.2128, 0.2151, 0.1976, 0.2107, 0.1749, 0.1564, 0.2007, 0.2101, 0.2115, 0.2151, 0.2007, 0.1674, 0.1641, 0.2232, 0.2085, 0.2282, 0.2176, 0.2108, 0.1726, 0.1533]
- `item_recalls`: [0.1345, 0.0968, 0.1037, 0.2329, 0.1954, 0.3027, 0.2585, 0.2346, 0.2740, 0.3088, 0.3230, 0.2912, 0.3096, 0.2599, 0.2417, 0.2866, 0.2980, 0.2967, 0.3064, 0.2903, 0.2625, 0.2374, 0.2860, 0.2739, 0.3118, 0.3173, 0.3106, 0.2725, 0.2249]
- `product_precisions`: [0.0003, 0.0007, 0.0004, 0.0025, 0.0007, 0.0003, 0.0014, 0.0018, 0.0021, 0.0018, 0.0025, 0.0032, 0.0018, 0.0007, 0.0007, 0.0011, 0.0032, 0.0021, 0.0035, 0.0018, 0.0018, 0.0015, 0.0035, 0.0028, 0.0028, 0.0025, 0.0004, 0.0015, 0.0018]
- `product_recalls`: [0.0002, 0.0004, 0.0002, 0.0014, 0.0009, 0.0003, 0.0016, 0.0023, 0.0014, 0.0025, 0.0019, 0.0046, 0.0017, 0.0006, 0.0009, 0.0011, 0.0041, 0.0020, 0.0028, 0.0015, 0.0019, 0.0018, 0.0040, 0.0030, 0.0020, 0.0020, 0.0003, 0.0013, 0.0023]

B.1.5 Metoda `brismf_daily_batch`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja [1e-1, 1e-4]
- `k`: naključno z območja [5, 50]
- `m`: naključno z območja [1e-1, 1e-3]
- `nbest_items`: 3
- `learn_rate`: naključno z območja [1e-2, 1e-4]
- `nbest_products`: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0553, 0.0493, 0.0440, 0.0344, 0.0137, 0.0191, 0.0205, 0.0182, 0.0123, 0.0385, 0.0304, 0.0168, 0.0449, 0.0150, 0.0205, 0.0149, 0.0396, 0.1379, 0.0213, 0.0084, 0.0386, 0.0324, 0.0370, 0.0112, 0.0365, 0.0092, 0.1448, 0.1021, 0.0240]
- **hist_item_recalls:** [0.0703, 0.0606, 0.0527, 0.0469, 0.0171, 0.0297, 0.0283, 0.0270, 0.0172, 0.0602, 0.0448, 0.0252, 0.0761, 0.0207, 0.0326, 0.0265, 0.0668, 0.2056, 0.0321, 0.0131, 0.0710, 0.0455, 0.0542, 0.0157, 0.0587, 0.0163, 0.2130, 0.1734, 0.0344]
- **itemRMSE:** [0.4184, 0.3772, 0.3662, 0.3574, 0.3473, 0.3529, 0.3621, 0.3647, 0.3504, 0.3420, 0.3415, 0.3387, 0.3269, 0.3570, 0.3676, 0.3375, 0.3378, 0.3419, 0.3377, 0.3450, 0.3573, 0.3672, 0.3512, 0.3563, 0.3425, 0.3467, 0.3371, 0.3482, 0.3634]
- **item_precisions:** [0.0924, 0.0756, 0.0735, 0.0632, 0.0309, 0.0504, 0.0334, 0.0309, 0.0377, 0.1351, 0.1393, 0.0392, 0.1357, 0.0228, 0.0485, 0.0274, 0.1261, 0.2167, 0.0605, 0.0214, 0.1004, 0.0815, 0.1460, 0.0213, 0.1377, 0.0195, 0.2137, 0.1320, 0.0734]
- **item_recalls:** [0.1345, 0.1178, 0.1092, 0.0911, 0.0441, 0.0776, 0.0525, 0.0436, 0.0532, 0.1898, 0.2026, 0.0555, 0.1946, 0.0290, 0.0701, 0.0404, 0.1731, 0.3074, 0.0833, 0.0317, 0.1620, 0.1105, 0.1804, 0.0270, 0.1803, 0.0269, 0.3145, 0.2170, 0.0984]
- **product_precisions:** [0.0007, 0.0003, 0.0000, 0.0018, 0.0011, 0.0010, 0.0007, 0.0011, 0.0004, 0.0014, 0.0018, 0.0025, 0.0009, 0.0000, 0.0004, 0.0007, 0.0018, 0.0018, 0.0010, 0.0004, 0.0000, 0.0004, 0.0018, 0.0018, 0.0003, 0.0004, 0.0007, 0.0022, 0.0004]
- **product_recalls:** [0.0004, 0.0005, 0.0000, 0.0015, 0.0012, 0.0011, 0.0008, 0.0016, 0.0011, 0.0020, 0.0015, 0.0014, 0.0007, 0.0000, 0.0002, 0.0005, 0.0021, 0.0020, 0.0010, 0.0011, 0.0000, 0.0003, 0.0023, 0.0010, 0.0002, 0.0004, 0.0007, 0.0029, 0.0004]

B.1.6 Metoda brismf_window

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja `[1e-1, 1e-4]`
- `k`: naključno z območja `[5, 50]`
- `m`: naključno z območja `[1e-1, 1e-3]`
- `nbest_items`: 3
- `window_length`: 7 dni
- `learn_rate`: naključno z območja `[1e-2, 1e-4]`
- `nbest_products`: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: `[0.0614, 0.0447, 0.0658, 0.0674, 0.0560, 0.0760, 0.0925, 0.0922, 0.2267, 0.1004, 0.0924, 0.2457, 0.0857, 0.0891, 0.0852, 0.2433, 0.1379, 0.1099, 0.2863, 0.0989, 0.1120, 0.1252, 0.2308]`
- `hist_item_recalls`: `[0.0562, 0.0425, 0.0884, 0.0934, 0.0773, 0.1037, 0.1186, 0.1045, 0.2419, 0.1337, 0.1212, 0.2537, 0.1186, 0.1227, 0.1163, 0.2436, 0.1752, 0.1327, 0.2867, 0.1340, 0.1348, 0.1422, 0.2356]`
- `itemRMSE`: `[0.3795, 0.3731, 0.3570, 0.3493, 0.3508, 0.3431, 0.3289, 0.3645, 0.3760, 0.3420, 0.3440, 0.3459, 0.3458, 0.3529, 0.3644, 0.3767, 0.3578, 0.3650, 0.3490, 0.3536, 0.3417, 0.3557, 0.3740]`
- `item_precisions`: `[0.1002, 0.0768, 0.1809, 0.1961, 0.2340, 0.2517, 0.2696, 0.2137, 0.2880, 0.2730, 0.2822, 0.3614, 0.2763, 0.2639, 0.2013, 0.2842, 0.2909, 0.2716, 0.3760, 0.2748, 0.2967, 0.2334, 0.2860]`
- `item_recalls`: `[0.1477, 0.1083, 0.2521, 0.2930, 0.3535, 0.3842, 0.3898, 0.3154, 0.4427, 0.3974, 0.4040, 0.5172, 0.3947, 0.3995, 0.3051, 0.4152, 0.3733, 0.3641, 0.5196, 0.4042, 0.4507, 0.3633, 0.4298]`

- `product_precisions`: [0.0000, 0.0004, 0.0011, 0.0007, 0.0000, 0.0011, 0.0004, 0.0007, 0.0014, 0.0004, 0.0011, 0.0014, 0.0017, 0.0004, 0.0000, 0.0000, 0.0028, 0.0000, 0.0021, 0.0014, 0.0004, 0.0011, 0.0007]
- `product_recalls`: [0.0000, 0.0005, 0.0011, 0.0007, 0.0000, 0.0004, 0.0002, 0.0005, 0.0013, 0.0001, 0.0011, 0.0016, 0.0016, 0.0005, 0.0000, 0.0000, 0.0020, 0.0000, 0.0015, 0.0016, 0.0011, 0.0010, 0.0008]

B.1.7 Metoda `ecocle_daily`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `max_user_clusters`: 8
- `evol_ncluster_limit`: 5
- `bregman_maxiters`: 20
- `max_item_clusters`: 8
- `ensemble_population_size`: 10
- `nbest_items`: 3
- `evolution_maxiters`: 20
- `nbest_products`: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `ecocle_rec`: [127150.0000, 132232.0000, 124110.0000, 117483.0000, 118663.0000, 123354.0000, 117996.0000, 129953.0000, 125133.0000, 124420.0000, 120946.0000, 114850.0000, 122968.0000, 120546.0000, 125872.0000, 131137.0000, 122960.0000, 117913.0000, 121355.0000, 121107.0000, 118810.0000, 125517.0000, 124557.0000]
- `fallback_rec`: [7424.0000, 7602.0000, 5682.0000, 1880.0000, 3800.0000, 5660.0000, 3908.0000, 3884.0000, 1854.0000, 7601.0000, 3808.0000, 5694.0000, 5718.0000,

3800.0000, 3624.0000, 3665.0000, 5700.0000, 5641.0000, 5725.0000, 5636.0000, 3748.0000, 1808.0000, 1844.0000]

- **hist_item_precisions:** [0.0041, 0.0032, 0.0056, 0.0197, 0.0202, 0.0118, 0.0159, 0.0036, 0.0178, 0.0123, 0.0154, 0.0209, 0.0192, 0.0111, 0.0040, 0.0015, 0.0021, 0.0025, 0.0035, 0.0004, 0.0130, 0.0129, 0.0132]
- **hist_item_recalls:** [0.0056, 0.0050, 0.0092, 0.0334, 0.0301, 0.0184, 0.0236, 0.0040, 0.0314, 0.0196, 0.0282, 0.0319, 0.0332, 0.0161, 0.0047, 0.0022, 0.0030, 0.0034, 0.0063, 0.0005, 0.0207, 0.0163, 0.0192]
- **itemRMSE:** [0.3854, 0.3723, 0.3683, 0.3695, 0.3777, 0.3865, 0.3810, 0.3895, 0.3946, 0.3982, 0.3926, 0.3958, 0.3918, 0.3970, 0.4065, 0.4093, 0.4114, 0.4065, 0.4071, 0.4032, 0.4043, 0.4072, 0.4073]
- **item_precisions:** [0.0097, 0.0032, 0.0067, 0.0422, 0.0593, 0.0322, 0.0581, 0.0057, 0.0205, 0.0147, 0.0207, 0.0263, 0.0245, 0.0154, 0.0052, 0.0018, 0.0025, 0.0032, 0.0063, 0.0004, 0.0288, 0.0232, 0.0184]
- **item_recalls:** [0.0125, 0.0035, 0.0065, 0.0571, 0.0785, 0.0414, 0.0751, 0.0056, 0.0300, 0.0169, 0.0275, 0.0355, 0.0298, 0.0191, 0.0051, 0.0016, 0.0026, 0.0035, 0.0067, 0.0004, 0.0371, 0.0276, 0.0203]
- **product_precisions:** [0.0000, 0.0007, 0.0000, 0.0000, 0.0000, 0.0011, 0.0005, 0.0000, 0.0000, 0.0000, 0.0000, 0.0021, 0.0010, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0005, 0.0000, 0.0004, 0.0000, 0.0080]
- **product_recalls:** [0.0000, 0.0006, 0.0000, 0.0000, 0.0000, 0.0004, 0.0004, 0.0000, 0.0000, 0.0000, 0.0000, 0.0025, 0.0005, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0003, 0.0000, 0.0011, 0.0000, 0.0023]

B.1.8 Metoda ecocle_daily_batch

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (**stvar**=**[žanr]**) Parametri, s katerimi je bila metoda pognana:

- **max_user_clusters:** 8

- evol_ncluster_limit: 5
- bregman_maxiters: 40
- max_item_clusters: 8
- ensemble_population_size: 10
- nbest_items: 3
- evolution_maxiters: 20
- nbest_products: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- hist_item_precisions: [0.0019, 0.0003, 0.0004, 0.0101, 0.0025, 0.0014, 0.0018, 0.0007, 0.0056, 0.0454, 0.0354, 0.0173, 0.0331, 0.0077, 0.0440, 0.0323, 0.0264, 0.0439, 0.0366, 0.0307, 0.0353, 0.0084, 0.0195, 0.0106, 0.0566, 0.0110, 0.0536, 0.0741, 0.0756]
- hist_item_recalls: [0.0016, 0.0005, 0.0004, 0.0165, 0.0058, 0.0027, 0.0031, 0.0009, 0.0094, 0.0782, 0.0628, 0.0253, 0.0578, 0.0127, 0.0690, 0.0621, 0.0425, 0.0618, 0.0608, 0.0531, 0.0680, 0.0117, 0.0375, 0.0184, 0.0850, 0.0201, 0.0828, 0.1221, 0.1131]
- itemRMSE: [0.4226, 0.3716, 0.3635, 0.3609, 0.3582, 0.3682, 0.3677, 0.3680, 0.3506, 0.3465, 0.3425, 0.3421, 0.3312, 0.3585, 0.3681, 0.3414, 0.3435, 0.3457, 0.3442, 0.3483, 0.3617, 0.3676, 0.3588, 0.3615, 0.3462, 0.3494, 0.3394, 0.3518, 0.3646]
- item_precisions: [0.0031, 0.0031, 0.0007, 0.0275, 0.0119, 0.0073, 0.0018, 0.0060, 0.0088, 0.1103, 0.0905, 0.0718, 0.1036, 0.0214, 0.0748, 0.0667, 0.0928, 0.0998, 0.1116, 0.1344, 0.0714, 0.0386, 0.0340, 0.0309, 0.1247, 0.0263, 0.1303, 0.1198, 0.1117]
- item_recalls: [0.0040, 0.0039, 0.0013, 0.0391, 0.0188, 0.0111, 0.0017, 0.0069, 0.0108, 0.1563, 0.1308, 0.1042, 0.1469, 0.0335, 0.1125, 0.0936, 0.1359, 0.1365, 0.1616, 0.1978, 0.1043, 0.0513, 0.0431, 0.0445, 0.1636, 0.0351, 0.1903, 0.1866, 0.1626]

- `product_precisions`: [0.0000, 0.0000, 0.0004, 0.0011, 0.0000, 0.0000, 0.0000, 0.0000, 0.0007, 0.0004, 0.0007, 0.0014, 0.0004, 0.0000, 0.0007, 0.0000, 0.0004, 0.0021, 0.0010, 0.0000, 0.0004, 0.0000, 0.0000, 0.0011, 0.0017, 0.0000, 0.0011, 0.0011, 0.0018]
- `product_recalls`: [0.0000, 0.0000, 0.0002, 0.0007, 0.0000, 0.0000, 0.0000, 0.0000, 0.0009, 0.0002, 0.0005, 0.0009, 0.0002, 0.0000, 0.0004, 0.0000, 0.0003, 0.0018, 0.0005, 0.0000, 0.0002, 0.0000, 0.0000, 0.0005, 0.0012, 0.0000, 0.0008, 0.0011, 0.0022]

B.1.9 Metoda `forget_history`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 3
- `nbest_products`: 3
- `history_forget_time`: 7 dni

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `itemRMSE`: [0.4026, 0.4006, 0.3925, 0.4069, 0.3968, 0.4175, 0.4364, 0.4367, 0.4285, 0.4190, 0.4055, 0.4130, 0.4053, 0.4292, 0.4389, 0.4229, 0.4168, 0.4158, 0.4110, 0.4094, 0.4351, 0.4381, 0.4298, 0.4331, 0.4219, 0.4260, 0.4141, 0.4308, 0.4439]
- `item_precisions`: [0.1939, 0.2574, 0.3051, 0.3259, 0.3126, 0.3026, 0.2507, 0.2733, 0.3105, 0.3092, 0.3119, 0.3089, 0.3062, 0.2600, 0.2539, 0.3084, 0.3295, 0.3087, 0.3267, 0.3088, 0.2491, 0.2467, 0.3189, 0.3039, 0.3096, 0.3074, 0.3141, 0.2544, 0.2484]
- `item_recalls`: [0.2851, 0.3940, 0.4470, 0.4545, 0.4394, 0.4477, 0.3676, 0.3835, 0.4378, 0.4443, 0.4658, 0.4618, 0.4385, 0.3825, 0.3812, 0.4420, 0.4687, 0.4369, 0.4571, 0.4632, 0.3786, 0.3535, 0.4085, 0.4002, 0.4191, 0.4415, 0.4697, 0.3944, 0.3564]

- `product_precisions`: [0.0017, 0.0003, 0.0007, 0.0028, 0.0021, 0.0014, 0.0004, 0.0004, 0.0007, 0.0004, 0.0018, 0.0018, 0.0011, 0.0007, 0.0014, 0.0028, 0.0025, 0.0007, 0.0014, 0.0011, 0.0026, 0.0007, 0.0014, 0.0007, 0.0010, 0.0014, 0.0004, 0.0011, 0.0004]
- `product_recalls`: [0.0019, 0.0002, 0.0007, 0.0031, 0.0024, 0.0020, 0.0011, 0.0011, 0.0014, 0.0003, 0.0013, 0.0014, 0.0007, 0.0005, 0.0014, 0.0042, 0.0023, 0.0011, 0.0012, 0.0007, 0.0016, 0.0006, 0.0020, 0.0004, 0.0006, 0.0017, 0.0011, 0.0018, 0.0005]

B.1.10 Metoda `forget_sunday_history`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (`stvar=[žanr]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 3
- `nbest_products`: 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `itemRMSE`: [0.3750, 0.3855, 0.3862, 0.3985, 0.3902, 0.4107, 0.4334, 0.3614, 0.3814, 0.3901, 0.3943, 0.4065, 0.3969, 0.4270, 0.3672, 0.3801, 0.3892, 0.3950, 0.4015, 0.4046, 0.4306, 0.3721, 0.3889, 0.4061, 0.4036, 0.4128, 0.4056, 0.4273, 0.3673]
- `item_precisions`: [0.0031, 0.1944, 0.2927, 0.3309, 0.3175, 0.3102, 0.2543, 0.0014, 0.2179, 0.3018, 0.3267, 0.3132, 0.3143, 0.2635, 0.1535, 0.2168, 0.3141, 0.3242, 0.3323, 0.3165, 0.2535, 0.0171, 0.2053, 0.2904, 0.3183, 0.3110, 0.3191, 0.2552, 0.0792]
- `item_recalls`: [0.0035, 0.3004, 0.4286, 0.4621, 0.4494, 0.4611, 0.3718, 0.0013, 0.3185, 0.4392, 0.4903, 0.4671, 0.4540, 0.3874, 0.2378, 0.3187, 0.4469, 0.4572, 0.4672, 0.4774, 0.3881, 0.0209, 0.2624, 0.3833, 0.4271, 0.4513, 0.4751, 0.3945, 0.1046]

- **product_precisions:** [0.0003, 0.0014, 0.0021, 0.0014, 0.0014, 0.0014, 0.0004, 0.0000, 0.0032, 0.0011, 0.0018, 0.0021, 0.0014, 0.0014, 0.0000, 0.0014, 0.0011, 0.0007, 0.0003, 0.0014, 0.0022, 0.0000, 0.0018, 0.0011, 0.0038, 0.0025, 0.0021, 0.0015, 0.0000]
- **product_recalls:** [0.0010, 0.0010, 0.0026, 0.0010, 0.0023, 0.0020, 0.0002, 0.0000, 0.0034, 0.0009, 0.0015, 0.0025, 0.0012, 0.0012, 0.0000, 0.0012, 0.0011, 0.0006, 0.0003, 0.0013, 0.0033, 0.0000, 0.0017, 0.0010, 0.0037, 0.0022, 0.0015, 0.0015, 0.0000]

B.1.11 Metoda history

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (**stvar=[žanr]**) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 3
- **nbest_products:** 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **itemRMSE:** [0.4026, 0.4006, 0.3925, 0.4069, 0.3968, 0.4175, 0.4364, 0.4407, 0.4334, 0.4262, 0.4113, 0.4233, 0.4186, 0.4459, 0.4535, 0.4373, 0.4314, 0.4355, 0.4287, 0.4257, 0.4569, 0.4578, 0.4497, 0.4591, 0.4447, 0.4429, 0.4322, 0.4474, 0.4641]
- **item_precisions:** [0.1939, 0.2574, 0.3051, 0.3259, 0.3126, 0.3026, 0.2507, 0.2712, 0.3013, 0.2982, 0.2968, 0.2930, 0.2851, 0.2343, 0.2294, 0.2870, 0.3025, 0.2799, 0.2921, 0.2793, 0.2171, 0.2238, 0.2849, 0.2727, 0.2778, 0.2694, 0.2774, 0.2194, 0.2162]
- **item_recalls:** [0.2851, 0.3940, 0.4470, 0.4545, 0.4394, 0.4477, 0.3676, 0.3795, 0.4239, 0.4255, 0.4422, 0.4374, 0.4073, 0.3367, 0.3383, 0.4071, 0.4275, 0.3948, 0.4071, 0.4156, 0.3256, 0.3121, 0.3600, 0.3567, 0.3693, 0.3836, 0.4152, 0.3358, 0.3096]

- **product_precisions:** [0.0028, 0.0007, 0.0004, 0.0021, 0.0025, 0.0014, 0.0018, 0.0004, 0.0011, 0.0021, 0.0004, 0.0004, 0.0004, 0.0011, 0.0011, 0.0007, 0.0007, 0.0011, 0.0014, 0.0018, 0.0011, 0.0007, 0.0018, 0.0021, 0.0014, 0.0011, 0.0011, 0.0007, 0.0007]
- **product_recalls:** [0.0031, 0.0005, 0.0005, 0.0026, 0.0030, 0.0017, 0.0022, 0.0004, 0.0017, 0.0026, 0.0005, 0.0004, 0.0002, 0.0015, 0.0007, 0.0006, 0.0005, 0.0007, 0.0013, 0.0017, 0.0015, 0.0004, 0.0018, 0.0019, 0.0018, 0.0017, 0.0018, 0.0011, 0.0014]

B.1.12 Metoda history_iknn_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (**stvar=[žanr]**) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 3
- **nbest_products:** 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0077, 0.0310, 0.0226, 0.0281, 0.0168, 0.0163, 0.0086, 0.0100, 0.0084, 0.0080, 0.0074, 0.0032, 0.0053, 0.0005, 0.0032, 0.0042, 0.0063, 0.0000, 0.0000, 0.0063, 0.0044, 0.0066, 0.0042, 0.0021, 0.0063, 0.0000, 0.0011, 0.0022, 0.0011]
- **hist_item_recalls:** [0.0068, 0.0211, 0.0168, 0.0222, 0.0139, 0.0129, 0.0046, 0.0049, 0.0047, 0.0041, 0.0046, 0.0013, 0.0035, 0.0004, 0.0018, 0.0027, 0.0038, 0.0000, 0.0000, 0.0044, 0.0018, 0.0038, 0.0025, 0.0011, 0.0031, 0.0000, 0.0011, 0.0009, 0.0005]
- **itemRMSE:** [0.4132, 0.4119, 0.4018, 0.4175, 0.4044, 0.4281, 0.4439, 0.4515, 0.4397, 0.4308, 0.4175, 0.4279, 0.4256, 0.4506, 0.4600, 0.4413, 0.4369, 0.4391, 0.4313, 0.4291, 0.4668, 0.4658, 0.4536, 0.4637, 0.4489, 0.4447, 0.4359, 0.4504, 0.4667]

- **item_precisions:** [0.1831, 0.2358, 0.2651, 0.2871, 0.2751, 0.2774, 0.2367, 0.2561, 0.2904, 0.2883, 0.2905, 0.2838, 0.2766, 0.2236, 0.2204, 0.2811, 0.2938, 0.2740, 0.2872, 0.2737, 0.2112, 0.2191, 0.2807, 0.2667, 0.2739, 0.2627, 0.2721, 0.2161, 0.2119]
- **item_recalls:** [0.2726, 0.3594, 0.3821, 0.3965, 0.3857, 0.4093, 0.3449, 0.3542, 0.4076, 0.4100, 0.4318, 0.4207, 0.3920, 0.3200, 0.3235, 0.3989, 0.4129, 0.3855, 0.4005, 0.4069, 0.3178, 0.3035, 0.3549, 0.3477, 0.3627, 0.3739, 0.4074, 0.3300, 0.3029]
- **product_precisions:** [0.0007, 0.0007, 0.0004, 0.0011, 0.0014, 0.0003, 0.0011, 0.0011, 0.0004, 0.0007, 0.0007, 0.0018, 0.0018, 0.0018, 0.0004, 0.0007, 0.0011, 0.0014, 0.0003, 0.0007, 0.0007, 0.0000, 0.0011, 0.0018, 0.0010, 0.0011, 0.0007, 0.0007, 0.0007]
- **product_recalls:** [0.0006, 0.0010, 0.0003, 0.0015, 0.0020, 0.0003, 0.0014, 0.0011, 0.0005, 0.0006, 0.0006, 0.0022, 0.0021, 0.0019, 0.0005, 0.0005, 0.0007, 0.0010, 0.0003, 0.0007, 0.0006, 0.0000, 0.0009, 0.0015, 0.0012, 0.0009, 0.0006, 0.0007, 0.0006]

B.1.13 Metoda iknn_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (**stvar=[žanr]**) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 3
- **nbest_products:** 3

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0143, 0.0413, 0.0438, 0.0537, 0.0442, 0.0670, 0.0756, 0.0839, 0.0855, 0.0832, 0.0951, 0.0764, 0.0805, 0.0648, 0.0881, 0.0874, 0.0940, 0.0976, 0.1032, 0.0968, 0.0896, 0.0984, 0.1005, 0.1073, 0.1267, 0.1061, 0.1074, 0.0942, 0.1079]

- **hist_item_recalls:** [0.0110, 0.0347, 0.0411, 0.0572, 0.0469, 0.0637, 0.0681, 0.0765, 0.0785, 0.0771, 0.0941, 0.0756, 0.0861, 0.0633, 0.0873, 0.0863, 0.1020, 0.1018, 0.1017, 0.1104, 0.0850, 0.0943, 0.0976, 0.1009, 0.1314, 0.1066, 0.1097, 0.0987, 0.1117]
- **itemRMSE:** [0.4010, 0.4002, 0.3927, 0.4013, 0.3919, 0.4104, 0.4258, 0.4358, 0.4149, 0.4071, 0.3965, 0.3961, 0.3945, 0.4183, 0.4277, 0.4046, 0.4049, 0.4004, 0.3998, 0.3983, 0.4271, 0.4297, 0.4153, 0.4215, 0.4045, 0.4063, 0.3954, 0.4050, 0.4214]
- **item_precisions:** [0.0415, 0.1484, 0.1941, 0.2115, 0.1905, 0.2039, 0.1699, 0.1982, 0.2056, 0.2110, 0.2196, 0.1969, 0.1906, 0.1617, 0.1712, 0.1937, 0.2181, 0.2093, 0.2246, 0.1895, 0.1641, 0.1630, 0.1842, 0.1851, 0.2128, 0.2119, 0.2080, 0.1656, 0.1678]
- **item_recalls:** [0.0598, 0.2215, 0.2704, 0.2937, 0.2588, 0.2974, 0.2482, 0.2721, 0.2874, 0.2921, 0.3231, 0.2964, 0.2711, 0.2304, 0.2465, 0.2768, 0.3066, 0.2983, 0.3104, 0.2712, 0.2446, 0.2240, 0.2332, 0.2404, 0.2851, 0.2944, 0.3132, 0.2549, 0.2448]
- **product_precisions:** [0.0000, 0.0000, 0.0014, 0.0021, 0.0011, 0.0017, 0.0007, 0.0018, 0.0007, 0.0007, 0.0011, 0.0007, 0.0007, 0.0025, 0.0007, 0.0014, 0.0004, 0.0014, 0.0014, 0.0000, 0.0011, 0.0025, 0.0014, 0.0014, 0.0017, 0.0014, 0.0004, 0.0007, 0.0000]
- **product_recalls:** [0.0000, 0.0000, 0.0022, 0.0023, 0.0008, 0.0025, 0.0005, 0.0023, 0.0013, 0.0005, 0.0017, 0.0007, 0.0009, 0.0042, 0.0005, 0.0020, 0.0004, 0.0019, 0.0026, 0.0000, 0.0009, 0.0018, 0.0017, 0.0012, 0.0020, 0.0017, 0.0004, 0.0006, 0.0000]

B.1.14 Metoda iknn_daily_batch

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari A (**stvar**=[žanr]) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 3

- hist_item_precisions: [0.0035, 0.0024, 0.0004, 0.0021, 0.0000, 0.0021, 0.0007, 0.0028, 0.0000, 0.0220, 0.0256, 0.0145, 0.1175, 0.0000, 0.0122, 0.0221, 0.0326, 0.1668, 0.0369, 0.1153, 0.0088, 0.0271, 0.0228, 0.0186, 0.0412, 0.0156, 0.0374, 0.0280, 0.0233]
- hist_item_recalls: [0.0043, 0.0031, 0.0005, 0.0041, 0.0000, 0.0033, 0.0011, 0.0044, 0.0000, 0.0418, 0.0385, 0.0247, 0.1849, 0.0000, 0.0209, 0.0415, 0.0524, 0.2083, 0.0543, 0.1771, 0.0151, 0.0347, 0.0367, 0.0283, 0.0531, 0.0311, 0.0504, 0.0341, 0.0316]
- itemRMSE: [0.3750, 0.3475, 0.3520, 0.3480, 0.3413, 0.3497, 0.3615, 0.3612, 0.3511, 0.3471, 0.3517, 0.3471, 0.3359, 0.3608, 0.3679, 0.3477, 0.3483, 0.3512, 0.3510, 0.3539, 0.3640, 0.3717, 0.3599, 0.3657, 0.3546, 0.3578, 0.3493, 0.3607, 0.3680]
- item_precisions: [0.0038, 0.0028, 0.0004, 0.0025, 0.0000, 0.0021, 0.0007, 0.0028, 0.0000, 0.1177, 0.1158, 0.1014, 0.1956, 0.0000, 0.0568, 0.1011, 0.1232, 0.2139, 0.1340, 0.1782, 0.0556, 0.0793, 0.1158, 0.1004, 0.1401, 0.1058, 0.1286, 0.0885, 0.0756]
- item_recalls: [0.0047, 0.0034, 0.0005, 0.0030, 0.0000, 0.0026, 0.0008, 0.0030, 0.0000, 0.1622, 0.1627, 0.1431, 0.2897, 0.0000, 0.0780, 0.1360, 0.1664, 0.3000, 0.1796, 0.2582, 0.0765, 0.1042, 0.1375, 0.1200, 0.1774, 0.1493, 0.1853, 0.1240, 0.1009]
- product_precisions: [0.0000, 0.0000, 0.0004, 0.0000, 0.0000, 0.0007, 0.0000, 0.0014, 0.0000, 0.0000, 0.0000, 0.0011, 0.0005, 0.0000, 0.0000, 0.0000, 0.0000, 0.0032, 0.0010, 0.0000, 0.0000, 0.0000, 0.0000, 0.0005, 0.0005, 0.0000, 0.0000, 0.0000, 0.0014]
- product_recalls: [0.0000, 0.0000, 0.0002, 0.0000, 0.0000, 0.0009, 0.0000, 0.0017, 0.0000, 0.0000, 0.0000, 0.0004, 0.0004, 0.0000, 0.0000, 0.0000, 0.0000,

0.0024, 0.0005, 0.0000, 0.0000, 0.0000, 0.0000, 0.0005, 0.0003, 0.0000, 0.0000,
0.0000, 0.0028]

B.2 Rezultati evalvacije pri definiciji stvari B

B.2.1 Metoda avg_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0021, 0.0010, 0.0257, 0.0181, 0.0086, 0.0093, 0.0028, 0.0039, 0.0076, 0.0066, 0.0101, 0.0093, 0.0103, 0.0038, 0.0079, 0.0064, 0.0146, 0.0129, 0.0115, 0.0159, 0.0031, 0.0065, 0.0092, 0.0133, 0.0227, 0.0121, 0.0109, 0.0062, 0.0137]
- `hist_item_recalls`: [0.0018, 0.0001, 0.0277, 0.0206, 0.0115, 0.0105, 0.0029, 0.0044, 0.0090, 0.0074, 0.0118, 0.0095, 0.0129, 0.0040, 0.0088, 0.0072, 0.0145, 0.0135, 0.0116, 0.0162, 0.0031, 0.0062, 0.0089, 0.0128, 0.0204, 0.0111, 0.0129, 0.0069, 0.0154]
- `itemRMSE`: [0.3253, 0.3017, 0.2972, 0.3008, 0.2913, 0.3009, 0.3114, 0.3151, 0.2994, 0.2954, 0.2935, 0.2862, 0.2868, 0.3007, 0.3119, 0.2924, 0.2923, 0.2923, 0.2935, 0.2941, 0.3079, 0.3186, 0.3138, 0.3172, 0.3050, 0.2972, 0.2943, 0.3040, 0.3180]
- `item_precisions`: [0.0023, 0.0142, 0.0307, 0.0191, 0.0087, 0.0098, 0.0032, 0.0059, 0.0079, 0.0072, 0.0103, 0.0101, 0.0109, 0.0059, 0.0115, 0.0065, 0.0155, 0.0131, 0.0127, 0.0164, 0.0055, 0.0092, 0.0093, 0.0136, 0.0529, 0.0128, 0.0109, 0.0146, 0.0328]

- **item_recalls:** [0.0024, 0.0128, 0.0263, 0.0168, 0.0074, 0.0089, 0.0030, 0.0058, 0.0070, 0.0063, 0.0092, 0.0086, 0.0101, 0.0053, 0.0110, 0.0060, 0.0127, 0.0112, 0.0107, 0.0145, 0.0048, 0.0080, 0.0078, 0.0114, 0.0454, 0.0102, 0.0106, 0.0149, 0.0352]
- **product_precisions:** [0.0008, 0.0014, 0.0031, 0.0008, 0.0016, 0.0019, 0.0024, 0.0014, 0.0020, 0.0018, 0.0020, 0.0022, 0.0030, 0.0019, 0.0011, 0.0018, 0.0024, 0.0042, 0.0032, 0.0029, 0.0022, 0.0051, 0.0034, 0.0026, 0.0028, 0.0027, 0.0031, 0.0029, 0.0037]
- **product_recalls:** [0.0007, 0.0009, 0.0024, 0.0004, 0.0007, 0.0012, 0.0016, 0.0009, 0.0009, 0.0009, 0.0009, 0.0009, 0.0014, 0.0012, 0.0008, 0.0009, 0.0011, 0.0019, 0.0013, 0.0015, 0.0014, 0.0008, 0.0015, 0.0016, 0.0015, 0.0010, 0.0025, 0.0017, 0.0017]

B.2.2 Metoda avg_daily_batch

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (**stvar**=[**žanr**, **leto izdelave**, **jezik**, **časovni opis z vikendom**]) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 8
- **nbest_products:** 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0021, 0.0010, 0.0015, 0.0017, 0.0013, 0.0020, 0.0009, 0.0010, 0.0006, 0.0015, 0.0009, 0.0006, 0.0010, 0.0014, 0.0006, 0.0006, 0.0015, 0.0021, 0.0005, 0.0005, 0.0001, 0.0006, 0.0014, 0.0003, 0.0015, 0.0003, 0.0010, 0.0022, 0.0021]
- **hist_item_recalls:** [0.0018, 0.0001, 0.0012, 0.0015, 0.0013, 0.0022, 0.0009, 0.0010, 0.0007, 0.0012, 0.0008, 0.0009, 0.0010, 0.0017, 0.0010, 0.0006, 0.0012, 0.0018, 0.0005, 0.0004, 0.0001, 0.0005, 0.0011, 0.0002, 0.0014, 0.0002, 0.0011, 0.0021, 0.0023]

- `itemRMSE`: [0.3253, 0.3024, 0.2942, 0.2984, 0.2895, 0.3002, 0.3102, 0.3140, 0.2970, 0.2932, 0.2909, 0.2844, 0.2867, 0.2982, 0.3106, 0.2908, 0.2901, 0.2894, 0.2918, 0.2932, 0.3058, 0.3161, 0.3123, 0.3145, 0.3032, 0.2960, 0.2931, 0.3034, 0.3155]
- `item_precisions`: [0.0023, 0.0142, 0.0020, 0.0020, 0.0015, 0.0020, 0.0011, 0.0010, 0.0008, 0.0016, 0.0010, 0.0008, 0.0010, 0.0014, 0.0006, 0.0006, 0.0015, 0.0023, 0.0005, 0.0005, 0.0003, 0.0006, 0.0014, 0.0003, 0.0015, 0.0003, 0.0010, 0.0022, 0.0024]
- `item_recalls`: [0.0024, 0.0128, 0.0016, 0.0015, 0.0011, 0.0017, 0.0011, 0.0009, 0.0007, 0.0013, 0.0008, 0.0009, 0.0008, 0.0014, 0.0006, 0.0005, 0.0011, 0.0017, 0.0004, 0.0004, 0.0003, 0.0005, 0.0011, 0.0002, 0.0013, 0.0002, 0.0010, 0.0020, 0.0023]
- `product_precisions`: [0.0008, 0.0023, 0.0009, 0.0005, 0.0010, 0.0013, 0.0011, 0.0004, 0.0011, 0.0005, 0.0013, 0.0006, 0.0009, 0.0011, 0.0011, 0.0003, 0.0010, 0.0008, 0.0000, 0.0004, 0.0010, 0.0004, 0.0011, 0.0008, 0.0009, 0.0003, 0.0009, 0.0013, 0.0018]
- `product_recalls`: [0.0005, 0.0017, 0.0006, 0.0003, 0.0005, 0.0009, 0.0010, 0.0003, 0.0009, 0.0003, 0.0008, 0.0004, 0.0005, 0.0009, 0.0010, 0.0002, 0.0006, 0.0005, 0.0000, 0.0003, 0.0008, 0.0003, 0.0006, 0.0006, 0.0005, 0.0001, 0.0006, 0.0012, 0.0015]

B.2.3 Metoda `avg_window`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `window_length`: 7 dni
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0009, 0.0018, 0.0005, 0.0010, 0.0005, 0.0009, 0.0009, 0.0014, 0.0029, 0.0003, 0.0005, 0.0011, 0.0050, 0.0043, 0.0031, 0.0014, 0.0059, 0.0040, 0.0044, 0.0031, 0.0049, 0.0042, 0.0030]
- `hist_item_recalls`: [0.0009, 0.0019, 0.0006, 0.0008, 0.0005, 0.0007, 0.0008, 0.0015, 0.0033, 0.0002, 0.0003, 0.0012, 0.0055, 0.0058, 0.0031, 0.0014, 0.0053, 0.0042, 0.0046, 0.0032, 0.0075, 0.0046, 0.0032]
- `itemRMSE`: [0.3106, 0.3146, 0.2991, 0.2948, 0.2928, 0.2851, 0.2867, 0.2984, 0.3110, 0.2919, 0.2912, 0.2913, 0.2932, 0.2943, 0.3053, 0.3166, 0.3144, 0.3181, 0.3055, 0.2972, 0.2935, 0.3031, 0.3160]
- `item_precisions`: [0.0011, 0.0018, 0.0006, 0.0014, 0.0008, 0.0010, 0.0009, 0.0014, 0.0029, 0.0003, 0.0005, 0.0013, 0.0049, 0.0043, 0.0033, 0.0015, 0.0064, 0.0041, 0.0050, 0.0032, 0.0049, 0.0053, 0.0049]
- `item_recalls`: [0.0011, 0.0016, 0.0006, 0.0011, 0.0006, 0.0008, 0.0006, 0.0013, 0.0027, 0.0002, 0.0003, 0.0011, 0.0045, 0.0045, 0.0028, 0.0013, 0.0051, 0.0037, 0.0041, 0.0026, 0.0058, 0.0051, 0.0045]
- `product_precisions`: [0.0015, 0.0003, 0.0010, 0.0005, 0.0004, 0.0008, 0.0021, 0.0018, 0.0011, 0.0011, 0.0008, 0.0014, 0.0011, 0.0013, 0.0015, 0.0012, 0.0009, 0.0006, 0.0006, 0.0006, 0.0008, 0.0043, 0.0012]
- `product_recalls`: [0.0012, 0.0002, 0.0009, 0.0003, 0.0002, 0.0004, 0.0014, 0.0016, 0.0008, 0.0006, 0.0005, 0.0008, 0.0007, 0.0009, 0.0010, 0.0006, 0.0004, 0.0003, 0.0003, 0.0003, 0.0004, 0.0032, 0.0007]

B.2.4 Metoda brismf_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja [1e-1, 1e-4]
- `k`: naključno z območja [5, 50]
- `m`: naključno z območja [1e-1, 1e-3]

- `nbest_items`: 8
- `learn_rate`: naključno z območja `[1e-2, 1e-4]`
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0100, 0.0129, 0.0329, 0.0275, 0.0215, 0.0144, 0.0034, 0.0104, 0.0192, 0.0247, 0.0258, 0.0238, 0.0228, 0.0039, 0.0103, 0.0163, 0.0324, 0.0377, 0.0400, 0.0308, 0.0073, 0.0215, 0.0340, 0.0510, 0.0661, 0.0515, 0.0486, 0.0186, 0.0255]
- `hist_item_recalls`: [0.0113, 0.0112, 0.0382, 0.0337, 0.0288, 0.0188, 0.0036, 0.0135, 0.0230, 0.0285, 0.0295, 0.0264, 0.0270, 0.0045, 0.0127, 0.0189, 0.0351, 0.0401, 0.0430, 0.0328, 0.0081, 0.0228, 0.0355, 0.0506, 0.0655, 0.0521, 0.0515, 0.0198, 0.0274]
- `itemRMSE`: [0.3441, 0.3111, 0.3015, 0.3021, 0.2928, 0.3015, 0.3122, 0.3151, 0.2988, 0.2942, 0.2925, 0.2856, 0.2865, 0.3003, 0.3114, 0.2912, 0.2918, 0.2903, 0.2917, 0.2920, 0.3070, 0.3172, 0.3106, 0.3140, 0.3018, 0.2954, 0.2935, 0.3035, 0.3169]
- `item_precisions`: [0.0123, 0.0144, 0.0428, 0.0295, 0.0227, 0.0151, 0.0044, 0.0130, 0.0201, 0.0263, 0.0273, 0.0254, 0.0236, 0.0059, 0.0154, 0.0182, 0.0346, 0.0393, 0.0428, 0.0321, 0.0111, 0.0276, 0.0376, 0.0578, 0.0739, 0.0599, 0.0553, 0.0250, 0.0367]
- `item_recalls`: [0.0134, 0.0147, 0.0390, 0.0269, 0.0213, 0.0147, 0.0043, 0.0139, 0.0183, 0.0239, 0.0242, 0.0223, 0.0216, 0.0060, 0.0180, 0.0166, 0.0299, 0.0350, 0.0385, 0.0292, 0.0116, 0.0264, 0.0336, 0.0515, 0.0656, 0.0536, 0.0506, 0.0255, 0.0370]
- `product_precisions`: [0.0029, 0.0011, 0.0011, 0.0028, 0.0020, 0.0025, 0.0015, 0.0018, 0.0021, 0.0018, 0.0027, 0.0020, 0.0025, 0.0023, 0.0021, 0.0012, 0.0025, 0.0035, 0.0034, 0.0030, 0.0020, 0.0026, 0.0033, 0.0018, 0.0017, 0.0026, 0.0030, 0.0017, 0.0044]

- `product_recalls`: [0.0016, 0.0010, 0.0007, 0.0017, 0.0013, 0.0018, 0.0011, 0.0016, 0.0012, 0.0010, 0.0015, 0.0012, 0.0014, 0.0013, 0.0014, 0.0007, 0.0013, 0.0019, 0.0015, 0.0017, 0.0011, 0.0020, 0.0018, 0.0009, 0.0007, 0.0011, 0.0018, 0.0010, 0.0019]

B.2.5 Metoda `brismf_daily_batch`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja [1e-1, 1e-4]
- `k`: naključno z območja [5, 50]
- `m`: naključno z območja [1e-1, 1e-3]
- `nbest_items`: 8
- `learn_rate`: naključno z območja [1e-2, 1e-4]
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0100, 0.0121, 0.0049, 0.0032, 0.0031, 0.0036, 0.0044, 0.0020, 0.0022, 0.0022, 0.0014, 0.0008, 0.0089, 0.0033, 0.0023, 0.0019, 0.0058, 0.0014, 0.0009, 0.0018, 0.0005, 0.0022, 0.0018, 0.0024, 0.0009, 0.0008, 0.0018, 0.0025, 0.0044]
- `hist_item_recalls`: [0.0113, 0.0078, 0.0068, 0.0033, 0.0036, 0.0037, 0.0061, 0.0027, 0.0025, 0.0018, 0.0012, 0.0009, 0.0100, 0.0037, 0.0027, 0.0018, 0.0056, 0.0013, 0.0010, 0.0018, 0.0005, 0.0026, 0.0017, 0.0022, 0.0008, 0.0005, 0.0020, 0.0026, 0.0047]
- `itemRMSE`: [0.3441, 0.3150, 0.2995, 0.3031, 0.2937, 0.3049, 0.3154, 0.3185, 0.2996, 0.2943, 0.2938, 0.2852, 0.2907, 0.3029, 0.3151, 0.2897, 0.2879, 0.2882, 0.2910, 0.2932, 0.3099, 0.3170, 0.3117, 0.3133, 0.3035, 0.2974, 0.2933, 0.3071, 0.3161]

- `item_precisions`: [0.0123, 0.0171, 0.0072, 0.0050, 0.0048, 0.0047, 0.0048, 0.0024, 0.0034, 0.0029, 0.0021, 0.0013, 0.0107, 0.0040, 0.0034, 0.0021, 0.0085, 0.0018, 0.0014, 0.0023, 0.0008, 0.0029, 0.0023, 0.0024, 0.0014, 0.0013, 0.0027, 0.0028, 0.0055]
- `item_recalls`: [0.0134, 0.0161, 0.0067, 0.0039, 0.0045, 0.0041, 0.0056, 0.0024, 0.0030, 0.0021, 0.0016, 0.0012, 0.0100, 0.0038, 0.0034, 0.0017, 0.0071, 0.0015, 0.0011, 0.0021, 0.0007, 0.0028, 0.0019, 0.0021, 0.0009, 0.0008, 0.0025, 0.0028, 0.0053]
- `product_precisions`: [0.0027, 0.0025, 0.0015, 0.0015, 0.0014, 0.0021, 0.0020, 0.0016, 0.0015, 0.0014, 0.0008, 0.0014, 0.0063, 0.0013, 0.0018, 0.0025, 0.0036, 0.0009, 0.0013, 0.0005, 0.0023, 0.0012, 0.0023, 0.0014, 0.0013, 0.0011, 0.0013, 0.0009, 0.0023]
- `product_recalls`: [0.0015, 0.0018, 0.0010, 0.0010, 0.0009, 0.0016, 0.0014, 0.0011, 0.0011, 0.0007, 0.0006, 0.0008, 0.0041, 0.0012, 0.0014, 0.0016, 0.0025, 0.0007, 0.0008, 0.0003, 0.0009, 0.0008, 0.0014, 0.0007, 0.0007, 0.0007, 0.0008, 0.0007, 0.0018]

B.2.6 Metoda brismf_window

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja [1e-1, 1e-4]
- `k`: naključno z območja [5, 50]
- `m`: naključno z območja [1e-1, 1e-3]
- `nbest_items`: 8
- `window_length`: 7 dni
- `learn_rate`: naključno z območja [1e-2, 1e-4]
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0044, 0.0035, 0.0031, 0.0019, 0.0032, 0.0028, 0.0040, 0.0070, 0.0049, 0.0036, 0.0060, 0.0072, 0.0136, 0.0118, 0.0064, 0.0049, 0.0144, 0.0168, 0.0211, 0.0286, 0.0337, 0.0111, 0.0101]
- **hist_item_recalls:** [0.0061, 0.0045, 0.0036, 0.0020, 0.0038, 0.0027, 0.0042, 0.0078, 0.0077, 0.0038, 0.0063, 0.0084, 0.0136, 0.0126, 0.0067, 0.0049, 0.0145, 0.0176, 0.0206, 0.0280, 0.0355, 0.0124, 0.0117]
- **itemRMSE:** [0.3154, 0.3170, 0.3010, 0.2953, 0.2958, 0.2854, 0.2881, 0.2998, 0.3141, 0.2925, 0.2911, 0.2901, 0.2924, 0.2939, 0.3062, 0.3172, 0.3140, 0.3170, 0.3044, 0.2974, 0.2936, 0.3045, 0.3156]
- **item_precisions:** [0.0048, 0.0056, 0.0048, 0.0036, 0.0047, 0.0041, 0.0052, 0.0071, 0.0052, 0.0049, 0.0077, 0.0080, 0.0156, 0.0141, 0.0075, 0.0059, 0.0196, 0.0220, 0.0272, 0.0388, 0.0452, 0.0125, 0.0131]
- **item_recalls:** [0.0056, 0.0053, 0.0040, 0.0029, 0.0043, 0.0035, 0.0046, 0.0068, 0.0058, 0.0044, 0.0065, 0.0074, 0.0136, 0.0128, 0.0069, 0.0052, 0.0167, 0.0207, 0.0234, 0.0338, 0.0435, 0.0124, 0.0132]
- **product_precisions:** [0.0025, 0.0012, 0.0010, 0.0014, 0.0009, 0.0019, 0.0020, 0.0040, 0.0014, 0.0015, 0.0010, 0.0018, 0.0011, 0.0023, 0.0059, 0.0000, 0.0022, 0.0013, 0.0019, 0.0009, 0.0015, 0.0059, 0.0011]
- **product_recalls:** [0.0016, 0.0008, 0.0006, 0.0008, 0.0006, 0.0012, 0.0013, 0.0031, 0.0010, 0.0008, 0.0006, 0.0009, 0.0006, 0.0014, 0.0014, 0.0000, 0.0014, 0.0007, 0.0010, 0.0005, 0.0009, 0.0023, 0.0008]

B.2.7 Metoda ecocle_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]) Parametri, s katerimi je bila metoda pognana:

- **max_user_clusters:** 8

- evol_ncluster_limit: 5
- bregman_maxiters: 20
- max_item_clusters: 8
- ensemble_population_size: 10
- nbest_items: 8
- evolution_maxiters: 20
- nbest_products: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- ecocle_rec: [702715.0000, 693107.0000, 783818.0000, 783588.0000, 770924.0000, 812084.0000, 823744.0000, 715241.0000, 704494.0000, 797325.0000, 812263.0000, 813353.0000, 845189.0000, 842230.0000, 699221.0000, 753437.0000, 823999.0000, 816554.0000, 822934.0000, 844253.0000, 827024.0000, 730500.0000, 757151.0000]
- fallback_rec: [237737.0000, 244083.0000, 135303.0000, 135540.0000, 131177.0000, 165252.0000, 151435.0000, 222059.0000, 208279.0000, 129517.0000, 129121.0000, 122924.0000, 121562.0000, 139243.0000, 208629.0000, 168583.0000, 125868.0000, 130044.0000, 102278.0000, 92238.0000, 97776.0000, 200035.0000, 163793.0000]
- hist_item_precisions: [0.0036, 0.0009, 0.0009, 0.0016, 0.0009, 0.0005, 0.0009, 0.0018, 0.0011, 0.0001, 0.0006, 0.0020, 0.0011, 0.0003, 0.0013, 0.0024, 0.0020, 0.0017, 0.0023, 0.0005, 0.0006, 0.0083, 0.0046]
- hist_item_recalls: [0.0039, 0.0010, 0.0012, 0.0016, 0.0008, 0.0004, 0.0009, 0.0017, 0.0012, 0.0001, 0.0006, 0.0016, 0.0010, 0.0002, 0.0012, 0.0026, 0.0017, 0.0013, 0.0025, 0.0004, 0.0005, 0.0107, 0.0054]
- itemRMSE: [0.3160, 0.3194, 0.3006, 0.2962, 0.2993, 0.2925, 0.2958, 0.3062, 0.3177, 0.2985, 0.2974, 0.2971, 0.2994, 0.3040, 0.3137, 0.3194, 0.3179, 0.3175, 0.3124, 0.3080, 0.3037, 0.3152, 0.3185]

- `item_precisions`: [0.0037, 0.0009, 0.0010, 0.0016, 0.0009, 0.0005, 0.0009, 0.0018, 0.0011, 0.0001, 0.0006, 0.0021, 0.0011, 0.0003, 0.0015, 0.0026, 0.0020, 0.0019, 0.0023, 0.0005, 0.0006, 0.0083, 0.0050]
- `item_recalls`: [0.0034, 0.0009, 0.0011, 0.0015, 0.0007, 0.0003, 0.0008, 0.0015, 0.0010, 0.0001, 0.0005, 0.0017, 0.0008, 0.0002, 0.0014, 0.0025, 0.0015, 0.0023, 0.0021, 0.0003, 0.0004, 0.0097, 0.0051]
- `product_precisions`: [0.0003, 0.0004, 0.0005, 0.0004, 0.0016, 0.0007, 0.0014, 0.0013, 0.0008, 0.0000, 0.0007, 0.0013, 0.0005, 0.0000, 0.0015, 0.0008, 0.0011, 0.0009, 0.0020, 0.0005, 0.0000, 0.0086, 0.0031]
- `product_recalls`: [0.0002, 0.0003, 0.0004, 0.0002, 0.0003, 0.0001, 0.0003, 0.0005, 0.0005, 0.0000, 0.0003, 0.0002, 0.0002, 0.0000, 0.0009, 0.0005, 0.0004, 0.0003, 0.0002, 0.0001, 0.0000, 0.0047, 0.0023]

B.2.8 Metoda `ecocle_daily_batch`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `max_user_clusters`: 8
- `evol_ncluster_limit`: 5
- `bregman_maxiters`: 40
- `max_item_clusters`: 8
- `ensemble_population_size`: 10
- `nbest_items`: 8
- `evolution_maxiters`: 20
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0036, 0.0006, 0.0030, 0.0019, 0.0011, 0.0013, 0.0024, 0.0009, 0.0018, 0.0010, 0.0014, 0.0005, 0.0013, 0.0016, 0.0010, 0.0006, 0.0006, 0.0011, 0.0009, 0.0009, 0.0011, 0.0012, 0.0011, 0.0011, 0.0015, 0.0004, 0.0018, 0.0006, 0.0041]
- **hist_item_recalls:** [0.0039, 0.0003, 0.0027, 0.0029, 0.0011, 0.0013, 0.0028, 0.0009, 0.0025, 0.0012, 0.0013, 0.0005, 0.0013, 0.0016, 0.0010, 0.0004, 0.0006, 0.0010, 0.0007, 0.0007, 0.0012, 0.0011, 0.0010, 0.0011, 0.0015, 0.0003, 0.0019, 0.0007, 0.0041]
- **itemRMSE:** [0.3443, 0.3121, 0.3034, 0.3017, 0.2932, 0.3055, 0.3145, 0.3190, 0.2980, 0.2937, 0.2947, 0.2859, 0.2904, 0.3014, 0.3155, 0.2921, 0.2901, 0.2890, 0.2917, 0.2955, 0.3100, 0.3164, 0.3127, 0.3127, 0.3033, 0.2979, 0.2945, 0.3086, 0.3158]
- **item_precisions:** [0.0036, 0.0083, 0.0035, 0.0022, 0.0013, 0.0014, 0.0025, 0.0010, 0.0019, 0.0011, 0.0015, 0.0005, 0.0013, 0.0016, 0.0010, 0.0006, 0.0006, 0.0011, 0.0009, 0.0009, 0.0013, 0.0012, 0.0011, 0.0011, 0.0015, 0.0004, 0.0018, 0.0006, 0.0051]
- **item_recalls:** [0.0038, 0.0071, 0.0029, 0.0020, 0.0009, 0.0012, 0.0025, 0.0008, 0.0019, 0.0012, 0.0012, 0.0004, 0.0010, 0.0013, 0.0009, 0.0004, 0.0005, 0.0009, 0.0007, 0.0006, 0.0012, 0.0010, 0.0009, 0.0009, 0.0014, 0.0003, 0.0017, 0.0006, 0.0046]
- **product_precisions:** [0.0001, 0.0022, 0.0009, 0.0022, 0.0006, 0.0009, 0.0006, 0.0005, 0.0005, 0.0004, 0.0010, 0.0000, 0.0007, 0.0004, 0.0005, 0.0005, 0.0013, 0.0008, 0.0004, 0.0000, 0.0015, 0.0008, 0.0003, 0.0006, 0.0000, 0.0001, 0.0011, 0.0002, 0.0015]
- **product_recalls:** [0.0001, 0.0014, 0.0004, 0.0004, 0.0002, 0.0007, 0.0004, 0.0002, 0.0003, 0.0004, 0.0001, 0.0000, 0.0002, 0.0002, 0.0003, 0.0001, 0.0001, 0.0002, 0.0003, 0.0000, 0.0006, 0.0003, 0.0001, 0.0002, 0.0000, 0.0001, 0.0003, 0.0001, 0.0005]

B.2.9 Metoda forget_history

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]) Parametri, s katerimi je bila metoda pognana:

- nbest_items: 8
- nbest_products: 8
- history_forget_time: 7 dni

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- itemRMSE: [0.3398, 0.3051, 0.3143, 0.3261, 0.3242, 0.3392, 0.3406, 0.3420, 0.3467, 0.3391, 0.3352, 0.3312, 0.3337, 0.3314, 0.3404, 0.3358, 0.3329, 0.3297, 0.3342, 0.3390, 0.3363, 0.3413, 0.3500, 0.3545, 0.3507, 0.3410, 0.3411, 0.3371, 0.3406]
- item_precisions: [0.1665, 0.0203, 0.2869, 0.2969, 0.2820, 0.2458, 0.2021, 0.2260, 0.2392, 0.2480, 0.2463, 0.2506, 0.2396, 0.2038, 0.2146, 0.2369, 0.2535, 0.2441, 0.2504, 0.2382, 0.2060, 0.2147, 0.2292, 0.2057, 0.2173, 0.2230, 0.2289, 0.1901, 0.2282]
- item_recalls: [0.1710, 0.0192, 0.2663, 0.2701, 0.2545, 0.2451, 0.2004, 0.2305, 0.2142, 0.2215, 0.2263, 0.2286, 0.2249, 0.1976, 0.2269, 0.2155, 0.2217, 0.2159, 0.2226, 0.2165, 0.2094, 0.2156, 0.2026, 0.1868, 0.1872, 0.1981, 0.2044, 0.1925, 0.2366]
- product_precisions: [0.0105, 0.0049, 0.0218, 0.0133, 0.0134, 0.0093, 0.0111, 0.0120, 0.0101, 0.0128, 0.0120, 0.0114, 0.0101, 0.0101, 0.0083, 0.0087, 0.0100, 0.0090, 0.0109, 0.0082, 0.0099, 0.0097, 0.0082, 0.0079, 0.0080, 0.0071, 0.0086, 0.0091, 0.0099]
- product_recalls: [0.0079, 0.0029, 0.0156, 0.0089, 0.0087, 0.0069, 0.0073, 0.0091, 0.0068, 0.0086, 0.0079, 0.0076, 0.0068, 0.0076, 0.0066, 0.0057, 0.0068, 0.0060, 0.0087, 0.0053, 0.0076, 0.0072, 0.0052, 0.0051, 0.0050, 0.0047, 0.0051, 0.0067, 0.0076]

B.2.10 Metoda `forget_sunday_history`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `itemRMSE`: [0.3253, 0.3040, 0.3131, 0.3256, 0.3241, 0.3391, 0.3289, 0.3140, 0.2994, 0.3130, 0.3186, 0.3215, 0.3284, 0.3201, 0.3111, 0.2954, 0.3047, 0.3166, 0.3267, 0.3346, 0.3260, 0.3162, 0.3135, 0.3308, 0.3340, 0.3322, 0.3355, 0.3255, 0.3151]
- `item_precisions`: [0.0023, 0.0142, 0.2790, 0.2967, 0.2820, 0.2457, 0.1551, 0.0010, 0.0006, 0.2932, 0.3058, 0.2845, 0.2533, 0.1723, 0.0006, 0.0006, 0.3059, 0.3030, 0.2864, 0.2558, 0.1640, 0.0006, 0.0014, 0.2447, 0.2721, 0.2573, 0.2432, 0.1618, 0.0024]
- `item_recalls`: [0.0024, 0.0128, 0.2577, 0.2695, 0.2545, 0.2447, 0.1532, 0.0009, 0.0006, 0.2618, 0.2846, 0.2616, 0.2377, 0.1696, 0.0006, 0.0005, 0.2672, 0.2683, 0.2575, 0.2333, 0.1661, 0.0005, 0.0011, 0.2241, 0.2367, 0.2283, 0.2177, 0.1624, 0.0023]
- `product_precisions`: [0.0008, 0.0019, 0.0208, 0.0146, 0.0132, 0.0097, 0.0129, 0.0006, 0.0015, 0.0199, 0.0173, 0.0128, 0.0089, 0.0101, 0.0008, 0.0004, 0.0188, 0.0150, 0.0116, 0.0102, 0.0112, 0.0012, 0.0009, 0.0158, 0.0134, 0.0103, 0.0083, 0.0097, 0.0013]
- `product_recalls`: [0.0007, 0.0012, 0.0147, 0.0096, 0.0090, 0.0080, 0.0081, 0.0004, 0.0011, 0.0136, 0.0124, 0.0084, 0.0062, 0.0075, 0.0006, 0.0003, 0.0129, 0.0100, 0.0080, 0.0068, 0.0076, 0.0008, 0.0005, 0.0109, 0.0083, 0.0065, 0.0057, 0.0074, 0.0011]

B.2.11 Metoda history

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `itemRMSE`: [0.3398, 0.3051, 0.3143, 0.3261, 0.3242, 0.3392, 0.3406, 0.3478, 0.3472, 0.3421, 0.3426, 0.3381, 0.3422, 0.3457, 0.3579, 0.3502, 0.3444, 0.3420, 0.3487, 0.3550, 0.3614, 0.3663, 0.3678, 0.3759, 0.3672, 0.3593, 0.3590, 0.3655, 0.3677]
- `item_precisions`: [0.1665, 0.0203, 0.2869, 0.2969, 0.2820, 0.2458, 0.2021, 0.2093, 0.2392, 0.2353, 0.2220, 0.2149, 0.2015, 0.1677, 0.1706, 0.1884, 0.1954, 0.1799, 0.1776, 0.1705, 0.1395, 0.1499, 0.1604, 0.1516, 0.1485, 0.1515, 0.1565, 0.1118, 0.1385]
- `item_recalls`: [0.1710, 0.0192, 0.2663, 0.2701, 0.2545, 0.2451, 0.2004, 0.2135, 0.2142, 0.2096, 0.2024, 0.1959, 0.1885, 0.1638, 0.1813, 0.1696, 0.1696, 0.1567, 0.1561, 0.1554, 0.1404, 0.1530, 0.1401, 0.1366, 0.1280, 0.1342, 0.1414, 0.1116, 0.1441]
- `product_precisions`: [0.0107, 0.0058, 0.0209, 0.0142, 0.0151, 0.0102, 0.0077, 0.0087, 0.0112, 0.0085, 0.0088, 0.0089, 0.0073, 0.0067, 0.0052, 0.0078, 0.0082, 0.0083, 0.0073, 0.0047, 0.0081, 0.0061, 0.0051, 0.0065, 0.0071, 0.0059, 0.0067, 0.0076, 0.0071]
- `product_recalls`: [0.0081, 0.0035, 0.0151, 0.0099, 0.0102, 0.0071, 0.0050, 0.0069, 0.0077, 0.0069, 0.0056, 0.0062, 0.0053, 0.0049, 0.0038, 0.0049, 0.0051, 0.0055, 0.0046, 0.0033, 0.0059, 0.0044, 0.0032, 0.0043, 0.0042, 0.0036, 0.0047, 0.0054, 0.0053]

B.2.12 Metoda `history_iknn_daily`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0167, 0.0405, 0.0137, 0.0105, 0.0058, 0.0085, 0.0114, 0.0210, 0.0074, 0.0114, 0.0051, 0.0076, 0.0083, 0.0068, 0.0115, 0.0070, 0.0039, 0.0055, 0.0037, 0.0065, 0.0080, 0.0121, 0.0049, 0.0099, 0.0056, 0.0077, 0.0055, 0.0083, 0.0125]
- `hist_item_recalls`: [0.0171, 0.0257, 0.0122, 0.0094, 0.0060, 0.0074, 0.0130, 0.0215, 0.0071, 0.0083, 0.0047, 0.0052, 0.0066, 0.0063, 0.0121, 0.0046, 0.0029, 0.0042, 0.0026, 0.0037, 0.0068, 0.0098, 0.0030, 0.0062, 0.0034, 0.0036, 0.0039, 0.0069, 0.0098]
- `itemRMSE`: [0.3588, 0.3146, 0.3350, 0.3429, 0.3400, 0.3528, 0.3604, 0.3688, 0.3596, 0.3535, 0.3563, 0.3476, 0.3527, 0.3613, 0.3744, 0.3586, 0.3510, 0.3519, 0.3557, 0.3619, 0.3792, 0.3814, 0.3788, 0.3857, 0.3750, 0.3670, 0.3672, 0.3815, 0.3797]
- `item_precisions`: [0.0364, 0.0364, 0.0208, 0.0238, 0.0229, 0.0307, 0.0238, 0.0578, 0.0315, 0.0384, 0.0357, 0.0323, 0.0366, 0.0260, 0.0495, 0.0340, 0.0327, 0.0332, 0.0342, 0.0397, 0.0232, 0.0616, 0.0283, 0.0358, 0.0374, 0.0312, 0.0355, 0.0298, 0.0631]
- `item_recalls`: [0.0378, 0.0352, 0.0181, 0.0199, 0.0199, 0.0272, 0.0262, 0.0599, 0.0272, 0.0316, 0.0312, 0.0277, 0.0320, 0.0249, 0.0539, 0.0297, 0.0277, 0.0270, 0.0279, 0.0342, 0.0232, 0.0640, 0.0235, 0.0306, 0.0301, 0.0250, 0.0301, 0.0294, 0.0690]

- **product_precisions:** [0.0046, 0.0020, 0.0043, 0.0034, 0.0058, 0.0045, 0.0030, 0.0039, 0.0047, 0.0055, 0.0057, 0.0048, 0.0058, 0.0052, 0.0040, 0.0052, 0.0059, 0.0047, 0.0054, 0.0043, 0.0042, 0.0035, 0.0037, 0.0050, 0.0051, 0.0048, 0.0053, 0.0043, 0.0058]
- **product_recalls:** [0.0034, 0.0012, 0.0031, 0.0022, 0.0037, 0.0034, 0.0022, 0.0029, 0.0032, 0.0037, 0.0037, 0.0032, 0.0037, 0.0038, 0.0029, 0.0033, 0.0038, 0.0030, 0.0038, 0.0033, 0.0030, 0.0026, 0.0027, 0.0034, 0.0032, 0.0030, 0.0034, 0.0030, 0.0046]

B.2.13 Metoda iknn_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (**stvar**=[žanr, leto izdelave, jezik, časovni opis z vikendom]) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 8
- **nbest_products:** 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0167, 0.0408, 0.0142, 0.0105, 0.0061, 0.0094, 0.0111, 0.0199, 0.0081, 0.0115, 0.0057, 0.0072, 0.0091, 0.0072, 0.0126, 0.0079, 0.0054, 0.0068, 0.0052, 0.0072, 0.0077, 0.0115, 0.0063, 0.0103, 0.0062, 0.0069, 0.0059, 0.0077, 0.0128]
- **hist_item_recalls:** [0.0174, 0.0259, 0.0130, 0.0101, 0.0066, 0.0089, 0.0133, 0.0228, 0.0084, 0.0099, 0.0061, 0.0063, 0.0080, 0.0074, 0.0150, 0.0059, 0.0044, 0.0059, 0.0041, 0.0050, 0.0077, 0.0108, 0.0044, 0.0081, 0.0047, 0.0050, 0.0049, 0.0077, 0.0144]
- **itemRMSE:** [0.3542, 0.3134, 0.3260, 0.3283, 0.3235, 0.3334, 0.3451, 0.3511, 0.3325, 0.3228, 0.3253, 0.3152, 0.3203, 0.3318, 0.3467, 0.3234, 0.3159, 0.3194, 0.3183, 0.3233, 0.3432, 0.3500, 0.3414, 0.3461, 0.3314, 0.3266, 0.3260, 0.3428, 0.3457]

- `item_precisions`: [0.0314, 0.0361, 0.0176, 0.0193, 0.0176, 0.0247, 0.0191, 0.0431, 0.0230, 0.0265, 0.0251, 0.0224, 0.0254, 0.0184, 0.0333, 0.0250, 0.0232, 0.0208, 0.0239, 0.0257, 0.0167, 0.0373, 0.0191, 0.0246, 0.0228, 0.0196, 0.0227, 0.0190, 0.0394]
- `item_recalls`: [0.0330, 0.0348, 0.0151, 0.0165, 0.0148, 0.0219, 0.0214, 0.0440, 0.0200, 0.0216, 0.0219, 0.0193, 0.0226, 0.0180, 0.0372, 0.0215, 0.0194, 0.0170, 0.0192, 0.0212, 0.0168, 0.0369, 0.0156, 0.0209, 0.0183, 0.0155, 0.0196, 0.0187, 0.0445]
- `product_precisions`: [0.0023, 0.0020, 0.0038, 0.0038, 0.0035, 0.0045, 0.0044, 0.0033, 0.0021, 0.0033, 0.0035, 0.0036, 0.0041, 0.0039, 0.0042, 0.0045, 0.0029, 0.0045, 0.0033, 0.0040, 0.0031, 0.0036, 0.0036, 0.0038, 0.0034, 0.0046, 0.0026, 0.0041, 0.0036]
- `product_recalls`: [0.0018, 0.0013, 0.0023, 0.0025, 0.0025, 0.0034, 0.0029, 0.0024, 0.0014, 0.0023, 0.0023, 0.0027, 0.0031, 0.0022, 0.0031, 0.0029, 0.0017, 0.0031, 0.0020, 0.0024, 0.0022, 0.0028, 0.0022, 0.0023, 0.0025, 0.0028, 0.0016, 0.0027, 0.0024]

B.2.14 Metoda `iknn_daily_batch`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari B (`stvar=[žanr, leto izdelave, jezik, časovni opis z vikendom]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0044, 0.0014, 0.0014, 0.0026, 0.0021, 0.0045, 0.0013, 0.0011, 0.0036, 0.0013, 0.0030, 0.0035, 0.0042, 0.0014, 0.0006, 0.0020, 0.0004, 0.0015, 0.0051, 0.0045, 0.0005, 0.0004, 0.0041, 0.0031, 0.0055, 0.0014, 0.0019, 0.0019, 0.0021]

- **hist_item_recalls:** [0.0049, 0.0005, 0.0010, 0.0026, 0.0025, 0.0056, 0.0014, 0.0012, 0.0045, 0.0010, 0.0039, 0.0041, 0.0055, 0.0017, 0.0010, 0.0019, 0.0004, 0.0013, 0.0057, 0.0059, 0.0007, 0.0003, 0.0038, 0.0033, 0.0057, 0.0010, 0.0017, 0.0019, 0.0023]
- **itemRMSE:** [0.3251, 0.3030, 0.2945, 0.2987, 0.2909, 0.3007, 0.3105, 0.3143, 0.2983, 0.2950, 0.2937, 0.2877, 0.2892, 0.2990, 0.3115, 0.2935, 0.2925, 0.2924, 0.2944, 0.2963, 0.3073, 0.3163, 0.3129, 0.3152, 0.3052, 0.2991, 0.2957, 0.3045, 0.3159]
- **item_precisions:** [0.0045, 0.0142, 0.0019, 0.0028, 0.0028, 0.0049, 0.0015, 0.0011, 0.0038, 0.0019, 0.0032, 0.0038, 0.0041, 0.0014, 0.0006, 0.0020, 0.0008, 0.0016, 0.0050, 0.0044, 0.0005, 0.0004, 0.0041, 0.0032, 0.0056, 0.0015, 0.0019, 0.0019, 0.0024]
- **item_recalls:** [0.0050, 0.0129, 0.0015, 0.0021, 0.0026, 0.0048, 0.0014, 0.0010, 0.0034, 0.0014, 0.0029, 0.0035, 0.0040, 0.0014, 0.0006, 0.0015, 0.0007, 0.0012, 0.0046, 0.0046, 0.0006, 0.0003, 0.0033, 0.0029, 0.0048, 0.0010, 0.0015, 0.0018, 0.0023]
- **product_precisions:** [0.0011, 0.0023, 0.0019, 0.0006, 0.0009, 0.0000, 0.0014, 0.0005, 0.0000, 0.0001, 0.0000, 0.0000, 0.0001, 0.0010, 0.0011, 0.0011, 0.0001, 0.0011, 0.0000, 0.0000, 0.0041, 0.0000, 0.0005, 0.0000, 0.0000, 0.0005, 0.0000, 0.0000, 0.0000]
- **product_recalls:** [0.0011, 0.0016, 0.0012, 0.0004, 0.0006, 0.0000, 0.0010, 0.0001, 0.0000, 0.0001, 0.0000, 0.0000, 0.0001, 0.0006, 0.0009, 0.0007, 0.0001, 0.0005, 0.0000, 0.0000, 0.0004, 0.0000, 0.0001, 0.0000, 0.0000, 0.0001, 0.0000, 0.0000, 0.0000]

B.3 Rezultati evalvacije pri definiciji stvari C

B.3.1 Metoda avg_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis`

brez vikenda]) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0027, 0.0087, 0.0114, 0.0029, 0.0034, 0.0073, 0.0027, 0.0035, 0.0038, 0.0060, 0.0064, 0.0080, 0.0040, 0.0157, 0.0092, 0.0075, 0.0127, 0.0310, 0.0302, 0.0343, 0.0463, 0.0355, 0.0424, 0.0529, 0.0110, 0.0453, 0.0053, 0.0474, 0.0100]
- `hist_item_recalls`: [0.0028, 0.0085, 0.0105, 0.0028, 0.0032, 0.0069, 0.0027, 0.0033, 0.0041, 0.0056, 0.0058, 0.0075, 0.0039, 0.0164, 0.0095, 0.0064, 0.0109, 0.0300, 0.0280, 0.0332, 0.0448, 0.0372, 0.0383, 0.0503, 0.0097, 0.0408, 0.0050, 0.0513, 0.0087]
- `itemRMSE`: [0.3230, 0.2996, 0.2963, 0.2993, 0.2906, 0.3005, 0.3088, 0.3137, 0.2981, 0.2945, 0.2926, 0.2856, 0.2861, 0.2987, 0.3103, 0.2913, 0.2915, 0.2917, 0.2927, 0.2934, 0.3060, 0.3164, 0.3128, 0.3163, 0.3043, 0.2966, 0.2937, 0.3026, 0.3159]
- `item_precisions`: [0.0041, 0.0094, 0.0142, 0.0039, 0.0050, 0.0096, 0.0063, 0.0040, 0.0068, 0.0084, 0.0092, 0.0109, 0.0075, 0.0186, 0.0104, 0.0084, 0.0153, 0.0395, 0.0393, 0.0413, 0.0583, 0.0428, 0.0497, 0.0600, 0.0136, 0.0519, 0.0086, 0.0526, 0.0109]
- `item_recalls`: [0.0046, 0.0083, 0.0114, 0.0035, 0.0044, 0.0084, 0.0080, 0.0033, 0.0065, 0.0077, 0.0080, 0.0099, 0.0070, 0.0178, 0.0096, 0.0074, 0.0128, 0.0351, 0.0351, 0.0388, 0.0579, 0.0428, 0.0427, 0.0543, 0.0115, 0.0442, 0.0085, 0.0554, 0.0091]
- `product_precisions`: [0.0020, 0.0025, 0.0020, 0.0005, 0.0011, 0.0025, 0.0007, 0.0000, 0.0020, 0.0018, 0.0020, 0.0022, 0.0030, 0.0000, 0.0000, 0.0018, 0.0024, 0.0042, 0.0033, 0.0029, 0.0029, 0.0000, 0.0034, 0.0020, 0.0026, 0.0021, 0.0029, 0.0004, 0.0007]

- `product_recalls`: [0.0018, 0.0015, 0.0013, 0.0003, 0.0006, 0.0014, 0.0004, 0.0000, 0.0009, 0.0009, 0.0009, 0.0009, 0.0014, 0.0000, 0.0000, 0.0009, 0.0011, 0.0019, 0.0013, 0.0015, 0.0018, 0.0000, 0.0015, 0.0010, 0.0010, 0.0008, 0.0019, 0.0003, 0.0005]

B.3.2 Metoda `avg_daily_batch`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0027, 0.0049, 0.0008, 0.0017, 0.0013, 0.0016, 0.0129, 0.0023, 0.0008, 0.0010, 0.0005, 0.0006, 0.0013, 0.0005, 0.0004, 0.0004, 0.0015, 0.0010, 0.0009, 0.0006, 0.0015, 0.0018, 0.0009, 0.0004, 0.0018, 0.0004, 0.0012, 0.0018, 0.0019]
- `hist_item_recalls`: [0.0028, 0.0052, 0.0010, 0.0017, 0.0014, 0.0018, 0.0164, 0.0025, 0.0008, 0.0011, 0.0004, 0.0008, 0.0011, 0.0005, 0.0004, 0.0003, 0.0015, 0.0008, 0.0008, 0.0005, 0.0015, 0.0016, 0.0008, 0.0003, 0.0018, 0.0003, 0.0012, 0.0021, 0.0023]
- `itemRMSE`: [0.3230, 0.3007, 0.2938, 0.2976, 0.2890, 0.2999, 0.3093, 0.3136, 0.2964, 0.2932, 0.2905, 0.2843, 0.2862, 0.2986, 0.3102, 0.2904, 0.2905, 0.2896, 0.2918, 0.2928, 0.3059, 0.3160, 0.3117, 0.3148, 0.3032, 0.2958, 0.2931, 0.3031, 0.3148]
- `item_precisions`: [0.0041, 0.0058, 0.0023, 0.0028, 0.0024, 0.0016, 0.0133, 0.0024, 0.0008, 0.0011, 0.0005, 0.0006, 0.0013, 0.0005, 0.0004, 0.0004, 0.0015, 0.0010, 0.0009, 0.0006, 0.0015, 0.0018, 0.0009, 0.0004, 0.0018, 0.0004, 0.0012, 0.0018, 0.0019]

- **item_recalls:** [0.0046, 0.0056, 0.0023, 0.0026, 0.0023, 0.0015, 0.0146, 0.0022, 0.0007, 0.0012, 0.0003, 0.0006, 0.0010, 0.0005, 0.0004, 0.0002, 0.0012, 0.0008, 0.0007, 0.0005, 0.0014, 0.0015, 0.0008, 0.0003, 0.0017, 0.0003, 0.0011, 0.0020, 0.0021]
- **product_precisions:** [0.0014, 0.0008, 0.0014, 0.0013, 0.0004, 0.0008, 0.0025, 0.0004, 0.0006, 0.0009, 0.0008, 0.0005, 0.0009, 0.0005, 0.0008, 0.0004, 0.0009, 0.0009, 0.0003, 0.0001, 0.0023, 0.0008, 0.0017, 0.0018, 0.0006, 0.0003, 0.0014, 0.0008, 0.0013]
- **product_recalls:** [0.0010, 0.0006, 0.0010, 0.0010, 0.0002, 0.0006, 0.0022, 0.0003, 0.0004, 0.0006, 0.0004, 0.0002, 0.0007, 0.0003, 0.0006, 0.0002, 0.0006, 0.0006, 0.0002, 0.0001, 0.0017, 0.0006, 0.0012, 0.0013, 0.0006, 0.0002, 0.0011, 0.0005, 0.0011]

B.3.3 Metoda avg_window

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 8
- **window_length:** 7 dni
- **nbest_products:** 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0133, 0.0027, 0.0005, 0.0010, 0.0006, 0.0003, 0.0013, 0.0005, 0.0010, 0.0018, 0.0001, 0.0011, 0.0010, 0.0006, 0.0028, 0.0021, 0.0043, 0.0021, 0.0017, 0.0040, 0.0035, 0.0049, 0.0031]
- **hist_item_recalls:** [0.0169, 0.0028, 0.0004, 0.0011, 0.0005, 0.0002, 0.0011, 0.0006, 0.0011, 0.0015, 0.0001, 0.0009, 0.0009, 0.0006, 0.0025, 0.0020, 0.0038, 0.0016, 0.0015, 0.0032, 0.0037, 0.0048, 0.0028]

- `itemRMSE`: [0.3112, 0.3159, 0.2987, 0.2950, 0.2923, 0.2851, 0.2866, 0.2993, 0.3124, 0.2917, 0.2915, 0.2917, 0.2934, 0.2943, 0.3064, 0.3179, 0.3143, 0.3186, 0.3060, 0.2973, 0.2940, 0.3036, 0.3175]
- `item_precisions`: [0.0138, 0.0028, 0.0008, 0.0010, 0.0006, 0.0003, 0.0013, 0.0005, 0.0016, 0.0018, 0.0003, 0.0011, 0.0011, 0.0006, 0.0034, 0.0038, 0.0066, 0.0048, 0.0041, 0.0060, 0.0067, 0.0083, 0.0055]
- `item_recalls`: [0.0151, 0.0024, 0.0006, 0.0010, 0.0004, 0.0002, 0.0010, 0.0006, 0.0016, 0.0013, 0.0002, 0.0008, 0.0009, 0.0006, 0.0028, 0.0036, 0.0055, 0.0041, 0.0035, 0.0046, 0.0071, 0.0090, 0.0050]
- `product_precisions`: [0.0016, 0.0004, 0.0009, 0.0011, 0.0003, 0.0010, 0.0006, 0.0004, 0.0006, 0.0008, 0.0003, 0.0009, 0.0005, 0.0003, 0.0009, 0.0009, 0.0010, 0.0008, 0.0000, 0.0000, 0.0005, 0.0036, 0.0018]
- `product_recalls`: [0.0016, 0.0002, 0.0007, 0.0007, 0.0001, 0.0007, 0.0004, 0.0002, 0.0005, 0.0005, 0.0002, 0.0005, 0.0003, 0.0003, 0.0006, 0.0007, 0.0003, 0.0003, 0.0000, 0.0000, 0.0002, 0.0010, 0.0006]

B.3.4 Metoda `brismf_daily`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari `C` (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja [1e-1, 1e-4]
- `k`: naključno z območja [5, 50]
- `m`: naključno z območja [1e-1, 1e-3]
- `nbest_items`: 8
- `learn_rate`: naključno z območja [1e-2, 1e-4]
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0144, 0.0079, 0.0102, 0.0126, 0.0095, 0.0102, 0.0111, 0.0240, 0.0502, 0.0473, 0.0697, 0.0530, 0.0609, 0.0493, 0.0438, 0.0679, 0.0683, 0.0731, 0.0750, 0.0638, 0.0627, 0.0478, 0.0795, 0.0860, 0.0929, 0.0752, 0.0957, 0.0804, 0.0676]
- **hist_item_recalls:** [0.0168, 0.0086, 0.0103, 0.0124, 0.0095, 0.0114, 0.0119, 0.0273, 0.0508, 0.0457, 0.0697, 0.0523, 0.0619, 0.0515, 0.0530, 0.0678, 0.0641, 0.0725, 0.0737, 0.0623, 0.0633, 0.0534, 0.0755, 0.0825, 0.0857, 0.0701, 0.0931, 0.0903, 0.0766]
- **itemRMSE:** [0.3402, 0.3092, 0.3004, 0.3000, 0.2919, 0.3026, 0.3101, 0.3137, 0.2973, 0.2939, 0.2915, 0.2850, 0.2856, 0.2990, 0.3105, 0.2907, 0.2907, 0.2899, 0.2912, 0.2913, 0.3055, 0.3149, 0.3099, 0.3136, 0.3018, 0.2949, 0.2930, 0.3030, 0.3146]
- **item_precisions:** [0.0191, 0.0103, 0.0136, 0.0150, 0.0130, 0.0136, 0.0139, 0.0260, 0.0544, 0.0574, 0.0801, 0.0638, 0.0692, 0.0602, 0.0513, 0.0714, 0.0744, 0.0788, 0.0819, 0.0696, 0.0708, 0.0524, 0.0846, 0.0933, 0.0997, 0.0810, 0.1004, 0.0859, 0.0722]
- **item_recalls:** [0.0207, 0.0093, 0.0116, 0.0128, 0.0113, 0.0127, 0.0151, 0.0256, 0.0493, 0.0505, 0.0729, 0.0582, 0.0658, 0.0592, 0.0571, 0.0646, 0.0634, 0.0700, 0.0736, 0.0634, 0.0693, 0.0534, 0.0746, 0.0841, 0.0862, 0.0701, 0.0913, 0.0919, 0.0754]
- **product_precisions:** [0.0011, 0.0019, 0.0042, 0.0020, 0.0032, 0.0021, 0.0015, 0.0015, 0.0021, 0.0024, 0.0030, 0.0026, 0.0035, 0.0013, 0.0014, 0.0023, 0.0024, 0.0045, 0.0044, 0.0046, 0.0047, 0.0028, 0.0067, 0.0048, 0.0074, 0.0062, 0.0061, 0.0046, 0.0039]
- **product_recalls:** [0.0009, 0.0012, 0.0026, 0.0012, 0.0019, 0.0015, 0.0010, 0.0011, 0.0016, 0.0016, 0.0019, 0.0013, 0.0018, 0.0008, 0.0008, 0.0014, 0.0013, 0.0026, 0.0024, 0.0030, 0.0034, 0.0019, 0.0055, 0.0028, 0.0039, 0.0033, 0.0039, 0.0032, 0.0030]

B.3.5 Metoda brismf_daily_batch

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari *C* (*stvar*=[*žanr*, *leto izdelave*, *jezik*, *časovni opis brez vikenda*]) Parametri, s katerimi je bila metoda pognana:

- *regularization_factor*: naključno z območja [1e-1, 1e-4]
- *k*: naključno z območja [5, 50]
- *m*: naključno z območja [1e-1, 1e-3]
- *nbest_items*: 8
- *learn_rate*: naključno z območja [1e-2, 1e-4]
- *nbest_products*: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- *hist_item_precisions*: [0.0144, 0.0133, 0.0086, 0.0055, 0.0037, 0.0044, 0.0108, 0.0030, 0.0019, 0.0023, 0.0034, 0.0019, 0.0061, 0.0039, 0.0029, 0.0018, 0.0022, 0.0027, 0.0026, 0.0021, 0.0057, 0.0023, 0.0030, 0.0039, 0.0030, 0.0243, 0.0019, 0.0133, 0.0024]
- *hist_item_recalls*: [0.0168, 0.0149, 0.0090, 0.0059, 0.0036, 0.0045, 0.0131, 0.0031, 0.0019, 0.0020, 0.0033, 0.0019, 0.0061, 0.0039, 0.0036, 0.0016, 0.0020, 0.0032, 0.0023, 0.0020, 0.0056, 0.0022, 0.0028, 0.0034, 0.0028, 0.0247, 0.0023, 0.0160, 0.0025]
- *itemRMSE*: [0.3402, 0.3133, 0.3006, 0.3009, 0.2923, 0.3037, 0.3168, 0.3173, 0.2974, 0.2941, 0.2895, 0.2846, 0.2879, 0.3004, 0.3146, 0.2914, 0.2906, 0.2888, 0.2911, 0.2908, 0.3075, 0.3146, 0.3113, 0.3115, 0.3015, 0.2959, 0.2930, 0.3058, 0.3147]
- *item_precisions*: [0.0191, 0.0167, 0.0139, 0.0095, 0.0087, 0.0091, 0.0163, 0.0042, 0.0042, 0.0055, 0.0059, 0.0052, 0.0093, 0.0062, 0.0053, 0.0030, 0.0034, 0.0038, 0.0035, 0.0038, 0.0075, 0.0028, 0.0038, 0.0052, 0.0045, 0.0274, 0.0037, 0.0156, 0.0036]

- `item_recalls`: [0.0207, 0.0157, 0.0126, 0.0092, 0.0082, 0.0088, 0.0186, 0.0041, 0.0040, 0.0050, 0.0055, 0.0050, 0.0087, 0.0054, 0.0057, 0.0029, 0.0029, 0.0042, 0.0029, 0.0032, 0.0078, 0.0025, 0.0033, 0.0043, 0.0040, 0.0248, 0.0040, 0.0169, 0.0037]
- `product_precisions`: [0.0011, 0.0015, 0.0016, 0.0018, 0.0016, 0.0024, 0.0029, 0.0018, 0.0020, 0.0014, 0.0024, 0.0004, 0.0016, 0.0011, 0.0005, 0.0011, 0.0017, 0.0019, 0.0014, 0.0014, 0.0028, 0.0012, 0.0020, 0.0042, 0.0008, 0.0193, 0.0022, 0.0040, 0.0008]
- `product_recalls`: [0.0008, 0.0011, 0.0009, 0.0013, 0.0012, 0.0016, 0.0019, 0.0014, 0.0016, 0.0008, 0.0015, 0.0005, 0.0012, 0.0008, 0.0004, 0.0008, 0.0010, 0.0011, 0.0008, 0.0008, 0.0021, 0.0011, 0.0015, 0.0029, 0.0005, 0.0091, 0.0013, 0.0029, 0.0005]

B.3.6 Metoda `brismf_window`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `regularization_factor`: naključno z območja [1e-1, 1e-4]
- `k`: naključno z območja [5, 50]
- `m`: naključno z območja [1e-1, 1e-3]
- `nbest_items`: 8
- `window_length`: 7 dni
- `learn_rate`: naključno z območja [1e-2, 1e-4]
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0108, 0.0034, 0.0039, 0.0067, 0.0070, 0.0035, 0.0092, 0.0126, 0.0148, 0.0202, 0.0206, 0.0179, 0.0237, 0.0212, 0.0138, 0.0233, 0.0531, 0.0465, 0.0678, 0.0652, 0.0569, 0.0691, 0.0515]

- `hist_item_recalls`: [0.0131, 0.0032, 0.0037, 0.0064, 0.0065, 0.0031, 0.0085, 0.0140, 0.0178, 0.0182, 0.0197, 0.0175, 0.0229, 0.0204, 0.0141, 0.0259, 0.0495, 0.0450, 0.0622, 0.0618, 0.0566, 0.0767, 0.0581]
- `itemRMSE`: [0.3168, 0.3194, 0.3001, 0.2957, 0.2925, 0.2855, 0.2886, 0.3011, 0.3155, 0.2923, 0.2912, 0.2905, 0.2929, 0.2935, 0.3075, 0.3173, 0.3126, 0.3172, 0.3045, 0.2973, 0.2942, 0.3053, 0.3177]
- `item_precisions`: [0.0163, 0.0068, 0.0069, 0.0098, 0.0093, 0.0059, 0.0116, 0.0177, 0.0172, 0.0226, 0.0246, 0.0210, 0.0284, 0.0257, 0.0176, 0.0285, 0.0580, 0.0518, 0.0730, 0.0705, 0.0607, 0.0762, 0.0577]
- `item_recalls`: [0.0186, 0.0069, 0.0059, 0.0087, 0.0081, 0.0055, 0.0104, 0.0177, 0.0190, 0.0197, 0.0214, 0.0188, 0.0252, 0.0242, 0.0184, 0.0297, 0.0505, 0.0474, 0.0625, 0.0621, 0.0560, 0.0823, 0.0607]
- `product_precisions`: [0.0026, 0.0023, 0.0020, 0.0023, 0.0037, 0.0015, 0.0044, 0.0018, 0.0017, 0.0023, 0.0022, 0.0029, 0.0016, 0.0018, 0.0034, 0.0019, 0.0035, 0.0037, 0.0064, 0.0045, 0.0040, 0.0035, 0.0046]
- `product_recalls`: [0.0016, 0.0017, 0.0014, 0.0015, 0.0025, 0.0010, 0.0019, 0.0012, 0.0011, 0.0015, 0.0014, 0.0018, 0.0012, 0.0014, 0.0022, 0.0013, 0.0019, 0.0024, 0.0038, 0.0028, 0.0028, 0.0025, 0.0031]

B.3.7 Metoda `ecocle_daily`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `max_user_clusters`: 8
- `evol_ncluster_limit`: 5
- `bregman_maxiters`: 20
- `max_item_clusters`: 8
- `ensemble_population_size`: 10

- `nbest_items`: 8
- `evolution_maxiters`: 20
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 08.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `ecocle_rec`: [807720.0000, 784375.0000, 813560.0000, 827412.0000, 810671.0000, 853856.0000, 855607.0000, 808365.0000, 807615.0000, 829115.0000, 855964.0000, 849026.0000, 879049.0000, 872006.0000, 795530.0000, 829908.0000, 865267.0000, 859821.0000, 848425.0000, 877594.0000, 864167.0000, 819784.0000, 815667.0000]
- `fallback_rec`: [132662.0000, 152815.0000, 105497.0000, 91716.0000, 91430.0000, 123480.0000, 119572.0000, 128859.0000, 105158.0000, 97641.0000, 85420.0000, 87251.0000, 87702.0000, 109467.0000, 112255.0000, 92112.0000, 84539.0000, 86777.0000, 76787.0000, 58897.0000, 60633.0000, 110701.0000, 105277.0000]
- `hist_item_precisions`: [0.0014, 0.0006, 0.0008, 0.0016, 0.0003, 0.0009, 0.0015, 0.0008, 0.0004, 0.0001, 0.0030, 0.0014, 0.0020, 0.0006, 0.0042, 0.0046, 0.0017, 0.0006, 0.0018, 0.0004, 0.0003, 0.0014, 0.0101]
- `hist_item_recalls`: [0.0013, 0.0008, 0.0008, 0.0017, 0.0003, 0.0010, 0.0013, 0.0006, 0.0004, 0.0001, 0.0026, 0.0011, 0.0019, 0.0006, 0.0038, 0.0045, 0.0015, 0.0007, 0.0018, 0.0003, 0.0003, 0.0014, 0.0106]
- `itemRMSE`: [0.3169, 0.3166, 0.3009, 0.2998, 0.2999, 0.2966, 0.2985, 0.3087, 0.3182, 0.3039, 0.3030, 0.3019, 0.3036, 0.3067, 0.3161, 0.3218, 0.3189, 0.3209, 0.3160, 0.3123, 0.3075, 0.3182, 0.3213]
- `item_precisions`: [0.0016, 0.0006, 0.0008, 0.0018, 0.0003, 0.0009, 0.0015, 0.0008, 0.0004, 0.0001, 0.0030, 0.0014, 0.0020, 0.0006, 0.0042, 0.0046, 0.0017, 0.0006, 0.0018, 0.0004, 0.0003, 0.0014, 0.0101]
- `item_recalls`: [0.0016, 0.0006, 0.0007, 0.0016, 0.0002, 0.0008, 0.0012, 0.0006, 0.0004, 0.0001, 0.0023, 0.0011, 0.0017, 0.0005, 0.0036, 0.0041, 0.0014, 0.0007, 0.0016, 0.0003, 0.0002, 0.0013, 0.0098]

- `product_precisions`: [0.0007, 0.0005, 0.0006, 0.0005, 0.0000, 0.0000, 0.0005, 0.0000, 0.0000, 0.0000, 0.0017, 0.0001, 0.0010, 0.0000, 0.0033, 0.0024, 0.0003, 0.0003, 0.0000, 0.0000, 0.0002, 0.0003, 0.0075]
- `product_recalls`: [0.0003, 0.0002, 0.0005, 0.0002, 0.0000, 0.0000, 0.0001, 0.0000, 0.0000, 0.0000, 0.0007, 0.0001, 0.0008, 0.0000, 0.0011, 0.0016, 0.0002, 0.0003, 0.0000, 0.0000, 0.0001, 0.0001, 0.0021]

B.3.8 Metoda `ecocle_daily_batch`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `max_user_clusters`: 8
- `evol_ncluster_limit`: 5
- `bregman_maxiters`: 40
- `max_item_clusters`: 8
- `ensemble_population_size`: 10
- `nbest_items`: 8
- `evolution_maxiters`: 20
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0034, 0.0014, 0.0042, 0.0012, 0.0010, 0.0006, 0.0015, 0.0010, 0.0006, 0.0011, 0.0011, 0.0010, 0.0013, 0.0008, 0.0011, 0.0001, 0.0013, 0.0013, 0.0006, 0.0009, 0.0027, 0.0017, 0.0014, 0.0031, 0.0017, 0.0005, 0.0017, 0.0009, 0.0048]
- `hist_item_recalls`: [0.0036, 0.0013, 0.0046, 0.0010, 0.0013, 0.0006, 0.0014, 0.0013, 0.0006, 0.0012, 0.0011, 0.0009, 0.0010, 0.0007, 0.0012, 0.0001, 0.0011,

0.0011, 0.0007, 0.0006, 0.0028, 0.0014, 0.0012, 0.0029, 0.0017, 0.0004, 0.0015, 0.0013, 0.0052]

- **itemRMSE:** [0.3394, 0.3118, 0.3005, 0.2992, 0.2921, 0.3036, 0.3138, 0.3155, 0.2973, 0.2940, 0.2910, 0.2866, 0.2899, 0.3021, 0.3124, 0.2921, 0.2910, 0.2897, 0.2918, 0.2940, 0.3082, 0.3146, 0.3113, 0.3123, 0.3034, 0.2979, 0.2937, 0.3077, 0.3137]
- **item_precisions:** [0.0036, 0.0016, 0.0043, 0.0013, 0.0011, 0.0009, 0.0018, 0.0010, 0.0006, 0.0013, 0.0014, 0.0011, 0.0013, 0.0008, 0.0011, 0.0001, 0.0013, 0.0013, 0.0006, 0.0009, 0.0027, 0.0017, 0.0014, 0.0031, 0.0017, 0.0009, 0.0017, 0.0009, 0.0048]
- **item_recalls:** [0.0034, 0.0015, 0.0036, 0.0010, 0.0010, 0.0007, 0.0018, 0.0011, 0.0006, 0.0014, 0.0012, 0.0010, 0.0010, 0.0007, 0.0012, 0.0001, 0.0010, 0.0010, 0.0006, 0.0006, 0.0025, 0.0013, 0.0012, 0.0026, 0.0015, 0.0008, 0.0013, 0.0013, 0.0048]
- **product_precisions:** [0.0028, 0.0007, 0.0087, 0.0011, 0.0010, 0.0000, 0.0003, 0.0005, 0.0001, 0.0009, 0.0010, 0.0008, 0.0010, 0.0000, 0.0017, 0.0005, 0.0009, 0.0007, 0.0014, 0.0021, 0.0038, 0.0010, 0.0003, 0.0082, 0.0003, 0.0001, 0.0006, 0.0003, 0.0039]
- **product_recalls:** [0.0008, 0.0003, 0.0014, 0.0003, 0.0001, 0.0000, 0.0001, 0.0003, 0.0002, 0.0004, 0.0001, 0.0003, 0.0001, 0.0000, 0.0004, 0.0001, 0.0002, 0.0004, 0.0005, 0.0002, 0.0013, 0.0004, 0.0001, 0.0011, 0.0004, 0.0001, 0.0002, 0.0001, 0.0016]

B.3.9 Metoda forget_history

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 8
- **nbest_products:** 8

- `history_forget_time`: 7 dni

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `itemRMSE`: [0.3383, 0.3287, 0.3296, 0.3365, 0.3327, 0.3462, 0.3615, 0.3602, 0.3563, 0.3457, 0.3425, 0.3357, 0.3377, 0.3469, 0.3586, 0.3468, 0.3390, 0.3355, 0.3407, 0.3447, 0.3569, 0.3608, 0.3569, 0.3612, 0.3551, 0.3460, 0.3461, 0.3577, 0.3671]
- `item_precisions`: [0.1704, 0.1908, 0.2208, 0.2105, 0.1904, 0.1830, 0.1635, 0.1573, 0.1670, 0.1877, 0.1813, 0.1890, 0.1650, 0.1537, 0.1468, 0.1676, 0.1935, 0.1826, 0.1779, 0.1748, 0.1570, 0.1509, 0.1664, 0.1619, 0.1746, 0.1847, 0.1780, 0.1543, 0.1634]
- `item_recalls`: [0.1763, 0.1803, 0.2072, 0.1930, 0.1725, 0.1840, 0.1687, 0.1650, 0.1509, 0.1686, 0.1674, 0.1774, 0.1585, 0.1578, 0.1568, 0.1554, 0.1702, 0.1643, 0.1578, 0.1603, 0.1645, 0.1568, 0.1465, 0.1470, 0.1549, 0.1666, 0.1650, 0.1611, 0.1734]
- `product_precisions`: [0.0102, 0.0078, 0.0099, 0.0100, 0.0087, 0.0079, 0.0077, 0.0051, 0.0074, 0.0092, 0.0093, 0.0083, 0.0077, 0.0073, 0.0057, 0.0077, 0.0061, 0.0082, 0.0094, 0.0088, 0.0065, 0.0064, 0.0066, 0.0069, 0.0080, 0.0073, 0.0083, 0.0054, 0.0080]
- `product_recalls`: [0.0079, 0.0051, 0.0064, 0.0068, 0.0059, 0.0061, 0.0055, 0.0037, 0.0054, 0.0061, 0.0059, 0.0054, 0.0050, 0.0047, 0.0040, 0.0047, 0.0038, 0.0051, 0.0064, 0.0060, 0.0045, 0.0040, 0.0044, 0.0048, 0.0052, 0.0046, 0.0051, 0.0039, 0.0053]

B.3.10 Metoda `forget_sunday_history`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8

- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `itemRMSE`: [0.3230, 0.3186, 0.3224, 0.3311, 0.3289, 0.3424, 0.3558, 0.3138, 0.3171, 0.3214, 0.3256, 0.3263, 0.3307, 0.3422, 0.3109, 0.3112, 0.3140, 0.3221, 0.3322, 0.3383, 0.3521, 0.3161, 0.3261, 0.3399, 0.3386, 0.3360, 0.3393, 0.3535, 0.3147]
- `item_precisions`: [0.0041, 0.1620, 0.2481, 0.2359, 0.2104, 0.1987, 0.1651, 0.0027, 0.1766, 0.2607, 0.2508, 0.2304, 0.1922, 0.1645, 0.0004, 0.1690, 0.2765, 0.2462, 0.2220, 0.2009, 0.1620, 0.0023, 0.1907, 0.2337, 0.2296, 0.2254, 0.2057, 0.1607, 0.0019]
- `item_recalls`: [0.0046, 0.1556, 0.2326, 0.2162, 0.1913, 0.2000, 0.1711, 0.0023, 0.1613, 0.2357, 0.2324, 0.2142, 0.1842, 0.1680, 0.0004, 0.1573, 0.2417, 0.2198, 0.1985, 0.1851, 0.1711, 0.0020, 0.1704, 0.2148, 0.2021, 0.2022, 0.1874, 0.1680, 0.0021]
- `product_precisions`: [0.0008, 0.0133, 0.0143, 0.0126, 0.0120, 0.0078, 0.0057, 0.0003, 0.0091, 0.0087, 0.0108, 0.0098, 0.0101, 0.0080, 0.0005, 0.0111, 0.0107, 0.0105, 0.0102, 0.0087, 0.0078, 0.0005, 0.0110, 0.0103, 0.0104, 0.0097, 0.0101, 0.0070, 0.0012]
- `product_recalls`: [0.0005, 0.0088, 0.0098, 0.0086, 0.0074, 0.0059, 0.0034, 0.0001, 0.0062, 0.0055, 0.0074, 0.0064, 0.0068, 0.0057, 0.0005, 0.0073, 0.0072, 0.0071, 0.0070, 0.0057, 0.0053, 0.0004, 0.0073, 0.0067, 0.0065, 0.0059, 0.0066, 0.0049, 0.0009]

B.3.11 Metoda history

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8

- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `itemRMSE`: [0.3383, 0.3287, 0.3296, 0.3365, 0.3327, 0.3462, 0.3615, 0.3632, 0.3599, 0.3514, 0.3519, 0.3445, 0.3451, 0.3609, 0.3705, 0.3617, 0.3516, 0.3481, 0.3553, 0.3620, 0.3783, 0.3826, 0.3760, 0.3821, 0.3718, 0.3638, 0.3643, 0.3799, 0.3883]
- `item_precisions`: [0.1704, 0.1908, 0.2208, 0.2105, 0.1904, 0.1830, 0.1635, 0.1513, 0.1465, 0.1617, 0.1491, 0.1503, 0.1240, 0.1138, 0.1021, 0.1221, 0.1409, 0.1294, 0.1192, 0.1092, 0.0997, 0.0962, 0.1026, 0.1008, 0.1112, 0.1147, 0.1036, 0.0820, 0.0956]
- `item_recalls`: [0.1763, 0.1803, 0.2072, 0.1930, 0.1725, 0.1840, 0.1687, 0.1591, 0.1323, 0.1463, 0.1381, 0.1414, 0.1191, 0.1164, 0.1089, 0.1127, 0.1244, 0.1175, 0.1065, 0.1036, 0.1043, 0.1009, 0.0899, 0.0932, 0.0995, 0.1049, 0.0986, 0.0868, 0.1037]
- `product_precisions`: [0.0098, 0.0079, 0.0094, 0.0098, 0.0108, 0.0068, 0.0066, 0.0063, 0.0084, 0.0072, 0.0082, 0.0069, 0.0075, 0.0061, 0.0030, 0.0062, 0.0055, 0.0061, 0.0057, 0.0066, 0.0046, 0.0041, 0.0064, 0.0048, 0.0048, 0.0050, 0.0049, 0.0049, 0.0053]
- `product_recalls`: [0.0078, 0.0053, 0.0061, 0.0064, 0.0077, 0.0053, 0.0043, 0.0047, 0.0059, 0.0049, 0.0058, 0.0051, 0.0054, 0.0043, 0.0022, 0.0043, 0.0037, 0.0037, 0.0036, 0.0041, 0.0032, 0.0031, 0.0037, 0.0031, 0.0030, 0.0032, 0.0032, 0.0032, 0.0037]

B.3.12 Metoda `history_iknn_daily`

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8

- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0246, 0.0290, 0.0299, 0.0238, 0.0135, 0.0145, 0.0123, 0.0121, 0.0140, 0.0180, 0.0137, 0.0132, 0.0085, 0.0087, 0.0068, 0.0118, 0.0129, 0.0096, 0.0100, 0.0083, 0.0098, 0.0051, 0.0098, 0.0096, 0.0083, 0.0060, 0.0082, 0.0109, 0.0047]
- `hist_item_recalls`: [0.0225, 0.0280, 0.0283, 0.0188, 0.0107, 0.0115, 0.0086, 0.0085, 0.0081, 0.0109, 0.0076, 0.0074, 0.0042, 0.0049, 0.0039, 0.0049, 0.0049, 0.0040, 0.0038, 0.0032, 0.0041, 0.0029, 0.0036, 0.0034, 0.0035, 0.0022, 0.0031, 0.0034, 0.0024]
- `itemRMSE`: [0.3583, 0.3460, 0.3457, 0.3513, 0.3452, 0.3573, 0.3766, 0.3779, 0.3699, 0.3602, 0.3619, 0.3522, 0.3551, 0.3723, 0.3824, 0.3683, 0.3596, 0.3551, 0.3609, 0.3682, 0.3882, 0.3921, 0.3845, 0.3902, 0.3784, 0.3712, 0.3699, 0.3879, 0.3955]
- `item_precisions`: [0.0503, 0.0624, 0.0744, 0.0749, 0.0641, 0.0671, 0.0612, 0.0676, 0.0721, 0.0910, 0.0857, 0.0885, 0.0723, 0.0600, 0.0553, 0.0834, 0.0996, 0.0813, 0.0825, 0.0789, 0.0619, 0.0662, 0.0688, 0.0700, 0.0779, 0.0866, 0.0803, 0.0590, 0.0667]
- `item_recalls`: [0.0519, 0.0598, 0.0703, 0.0702, 0.0601, 0.0690, 0.0665, 0.0711, 0.0652, 0.0817, 0.0794, 0.0839, 0.0693, 0.0627, 0.0595, 0.0764, 0.0886, 0.0745, 0.0740, 0.0748, 0.0652, 0.0700, 0.0609, 0.0648, 0.0710, 0.0785, 0.0774, 0.0637, 0.0752]
- `product_precisions`: [0.0041, 0.0039, 0.0058, 0.0060, 0.0045, 0.0043, 0.0049, 0.0043, 0.0039, 0.0040, 0.0045, 0.0045, 0.0040, 0.0049, 0.0033, 0.0050, 0.0045, 0.0066, 0.0057, 0.0038, 0.0028, 0.0035, 0.0036, 0.0046, 0.0036, 0.0050, 0.0037, 0.0040, 0.0046]
- `product_recalls`: [0.0036, 0.0027, 0.0041, 0.0041, 0.0032, 0.0036, 0.0032, 0.0030, 0.0028, 0.0029, 0.0033, 0.0028, 0.0026, 0.0032, 0.0025, 0.0033, 0.0030,

0.0046, 0.0042, 0.0025, 0.0020, 0.0025, 0.0027, 0.0031, 0.0022, 0.0033, 0.0025, 0.0031, 0.0034]

B.3.13 Metoda iknn_daily

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (`stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]`) Parametri, s katerimi je bila metoda pognana:

- `nbest_items`: 8
- `nbest_products`: 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- `hist_item_precisions`: [0.0253, 0.0307, 0.0316, 0.0257, 0.0151, 0.0161, 0.0160, 0.0137, 0.0159, 0.0201, 0.0156, 0.0166, 0.0112, 0.0100, 0.0097, 0.0138, 0.0183, 0.0203, 0.0157, 0.0159, 0.0140, 0.0101, 0.0132, 0.0167, 0.0100, 0.0149, 0.0172, 0.0140, 0.0089]
- `hist_item_recalls`: [0.0240, 0.0302, 0.0310, 0.0222, 0.0130, 0.0149, 0.0130, 0.0121, 0.0123, 0.0150, 0.0110, 0.0117, 0.0077, 0.0073, 0.0078, 0.0088, 0.0109, 0.0122, 0.0098, 0.0097, 0.0099, 0.0075, 0.0082, 0.0107, 0.0070, 0.0090, 0.0105, 0.0097, 0.0067]
- `itemRMSE`: [0.3533, 0.3369, 0.3315, 0.3335, 0.3241, 0.3339, 0.3506, 0.3528, 0.3348, 0.3259, 0.3284, 0.3155, 0.3216, 0.3377, 0.3471, 0.3245, 0.3220, 0.3196, 0.3196, 0.3262, 0.3444, 0.3500, 0.3428, 0.3461, 0.3342, 0.3275, 0.3244, 0.3382, 0.3477]
- `item_precisions`: [0.0457, 0.0580, 0.0684, 0.0645, 0.0527, 0.0554, 0.0514, 0.0521, 0.0587, 0.0675, 0.0620, 0.0612, 0.0516, 0.0426, 0.0413, 0.0573, 0.0698, 0.0583, 0.0552, 0.0502, 0.0456, 0.0414, 0.0450, 0.0490, 0.0473, 0.0518, 0.0524, 0.0433, 0.0412]
- `item_recalls`: [0.0471, 0.0554, 0.0648, 0.0607, 0.0497, 0.0568, 0.0556, 0.0555, 0.0542, 0.0605, 0.0579, 0.0577, 0.0492, 0.0447, 0.0448, 0.0534, 0.0618, 0.0527,

0.0485, 0.0459, 0.0488, 0.0432, 0.0407, 0.0459, 0.0433, 0.0479, 0.0501, 0.0447, 0.0460]

- **product_precisions:** [0.0031, 0.0029, 0.0041, 0.0039, 0.0048, 0.0038, 0.0038, 0.0052, 0.0026, 0.0036, 0.0040, 0.0034, 0.0024, 0.0029, 0.0021, 0.0034, 0.0044, 0.0044, 0.0036, 0.0043, 0.0036, 0.0032, 0.0034, 0.0036, 0.0037, 0.0034, 0.0036, 0.0031, 0.0039]
- **product_recalls:** [0.0022, 0.0019, 0.0029, 0.0027, 0.0032, 0.0028, 0.0022, 0.0039, 0.0017, 0.0025, 0.0030, 0.0024, 0.0018, 0.0018, 0.0016, 0.0021, 0.0028, 0.0030, 0.0024, 0.0027, 0.0027, 0.0023, 0.0022, 0.0022, 0.0023, 0.0021, 0.0025, 0.0022, 0.0028]

B.3.14 Metoda iknn_daily_batch

Učenje se je pričelo 01.06.2013 in končalo 01.07.2013 (ne vključno). Uporabljena je bila definicija stvari C (stvar=[žanr, leto izdelave, jezik, časovni opis brez vikenda]) Parametri, s katerimi je bila metoda pognana:

- **nbest_items:** 8
- **nbest_products:** 8

Rezultati evalvacije so podani kot seznam, prvi dan evalvacije je 02.06.2013, zadnji dan je 30.06.2013 (vključno). Vrednosti v seznamu so urejene po dnevih.

- **hist_item_precisions:** [0.0026, 0.0049, 0.0011, 0.0023, 0.0013, 0.0024, 0.0130, 0.0023, 0.0020, 0.0011, 0.0015, 0.0013, 0.0023, 0.0005, 0.0006, 0.0016, 0.0003, 0.0024, 0.0014, 0.0006, 0.0026, 0.0016, 0.0015, 0.0011, 0.0010, 0.0004, 0.0010, 0.0019, 0.0019]
- **hist_item_recalls:** [0.0029, 0.0054, 0.0014, 0.0022, 0.0014, 0.0025, 0.0165, 0.0024, 0.0019, 0.0009, 0.0014, 0.0016, 0.0021, 0.0005, 0.0005, 0.0013, 0.0003, 0.0020, 0.0013, 0.0005, 0.0027, 0.0013, 0.0014, 0.0009, 0.0010, 0.0003, 0.0011, 0.0022, 0.0023]
- **itemRMSE:** [0.3230, 0.3013, 0.2952, 0.2987, 0.2911, 0.3013, 0.3099, 0.3140, 0.2985, 0.2959, 0.2938, 0.2883, 0.2893, 0.3000, 0.3107, 0.2938, 0.2938, 0.2934,

0.2952, 0.2967, 0.3078, 0.3160, 0.3128, 0.3159, 0.3056, 0.2997, 0.2965, 0.3052, 0.3151]

- **item_precisions:** [0.0039, 0.0059, 0.0028, 0.0033, 0.0024, 0.0047, 0.0151, 0.0027, 0.0034, 0.0014, 0.0032, 0.0033, 0.0044, 0.0006, 0.0006, 0.0016, 0.0004, 0.0024, 0.0014, 0.0006, 0.0047, 0.0024, 0.0037, 0.0011, 0.0010, 0.0004, 0.0010, 0.0019, 0.0019]
- **item_recalls:** [0.0044, 0.0058, 0.0028, 0.0028, 0.0023, 0.0045, 0.0181, 0.0023, 0.0031, 0.0010, 0.0029, 0.0030, 0.0042, 0.0006, 0.0005, 0.0012, 0.0004, 0.0017, 0.0011, 0.0004, 0.0056, 0.0021, 0.0033, 0.0008, 0.0009, 0.0003, 0.0010, 0.0021, 0.0021]
- **product_precisions:** [0.0014, 0.0018, 0.0007, 0.0071, 0.0006, 0.0000, 0.0018, 0.0000, 0.0000, 0.0001, 0.0000, 0.0000, 0.0002, 0.0003, 0.0000, 0.0000, 0.0000, 0.0019, 0.0000, 0.0000, 0.0010, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0008]
- **product_recalls:** [0.0013, 0.0011, 0.0002, 0.0005, 0.0004, 0.0000, 0.0013, 0.0000, 0.0000, 0.0001, 0.0000, 0.0000, 0.0001, 0.0001, 0.0000, 0.0000, 0.0000, 0.0012, 0.0000, 0.0000, 0.0001, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0000, 0.0007]